

LAPORAN TESIS

**SEGMENTASI, PENGUKURAN LUASAN, DAN
COLORIMETRY PADA SCAR KELOID
MENGUNAKAN MULTI-TASK LEARNING
BERBASIS CNN DAN LSTM**

Lailatul Hayani
NIM. 2356102020

DOSEN PEMBIMBING
Ananda, S.Kom., M.T., Ph.D.
Erwin Setyo Nugroho S.T., M.Eng.

PROGRAM STUDI
MAGISTER TERAPAN TEKNIK KOMPUTER
POLITEKNIK CALTEX RIAU
2026

**SEGMENTASI, PENGUKURAN LUASAN, DAN
COLORIMETRY PADA SCAR KELOID MENGGUNAKAN
MULTI-TASK LEARNING BERBASIS CNN DAN LSTM**

Lailatul Hayani

NIM. 2356102020

DOSEN PEMBIMBING

Ananda, S.Kom., M.T., Ph.D.

Erwin Setyo Nugroho S.T., M.Eng.

PROGRAM STUDI

MAGISTER TERAPAN TEKNIK KOMPUTER

POLITEKNIK CALTEX RIAU

2026

**SEGMENTASI, PENGUKURAN LUASAN, DAN
COLORIMETRY PADA SCAR KELOID MENGGUNAKAN
MULTI-TASK LEARNING BERBASIS CNN DAN LSTM**

Lailatul Hayani

NIM. 2356102020

DOSEN PEMBIMBING

Ananda, S.Kom, M.T., Ph.D.

Erwin Setyo Nugroho S.T., M.Eng.

PROGRAM STUDI

MAGISTER TERAPAN TEKNIK KOMPUTER

POLITEKNIK CALTEX RIAU

2026

HALAMAN PENGESAHAN

SEGMENTASI, PENGUKURAN LUASAN, DAN COLORIMETRY
PADA SCAR KELOID MENGGUNAKAN
MULTI-TASK LEARNING BERBASIS CNN DAN LSTM

Oleh:

Lailatul Hayani

NIM. 2356102020

Tesis ini digunakan sebagai salah satu syarat untuk memperoleh

Gelar Magister Terapan (M.Tr.Kom.)

di

Politeknik Caltex Riau

2026

Disetujui oleh:

Pembimbing Utama	: <u>Ananda, S.Kom, M.T., Ph.D.</u> NIP. 108501
Pembimbing Pendamping	: <u>Erwin Setyo Nugroho, S.T., M.Eng.</u> NIP. 027614
Penguji	: <u>Dr. Eng. Yoanda Alim Syahbana, S.T., M.Sc.</u> NIP. 148809
Penguji	: <u>Dr. Ir. Emansa Hasri Putra, S.T., M.Eng</u> NIP. 017501
Penguji	: <u>Dr. Juni Nurma Sari, S.Kom., M.MT.</u> NIP. 017218

Ananda
(*Erwin*)

(*Yoanda*)
(*Emansa*)
(*Juni*)

Mengetahui,

Ketua Program Studi Magister Terapan Teknik Komputer

Politeknik Caltex Riau



Dr. Eng. Yoanda Alim Syahbana, S.T., M.Sc.
NIP. 148809

HALAMAN PERNYATAAN ORISINALITAS

Dengan ini saya menyatakan bahwa bagian atau keseluruhan tesis ini:

1. Adalah hasil karya sendiri dan tidak mengandung unsur plagiat dari pihak lain.
2. Tidak pernah diajukan untuk mendapatkan gelar akademis pada suatu Perguruan Tinggi .
3. Tidak pernah dipublikasikan atau ditulis oleh pihak lain .
4. Mencantumkan rujukan dan kutipan dengan jujur dan benar terhadap sumber referensi lain yang menunjang pembahasan pada tesis.

Apabila ditemukan bukti bahwa pernyataan saya diatas tidak benar, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku di Politeknik Caltex Riau.

Pekanbaru, 10 Februari 2026

Yang menyatakan,

(Lailatul Hayani)

HALAMAN KESEPAKATAN PUBLIKASI

Demi pengembangan ilmu pengetahuan, dengan ini saya menyatakan:

1. Memberikan persetujuan kepada Politeknik Caltex Riau untuk menyimpan, mengolah dalam bentuk pangkalan data, merawat, mengalih media/formatkan dan mempublikasikan tesis ini selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.
2. Tidak melakukan alih media/format dan publikasi dalam bentuk makalah ilmiah dari bagian atau keseluruhan tesis ini ke suatu publikasi ilmiah, pada seminar ataupun jurnal, skala nasional maupun internasional, kecuali ada persetujuan dari saya dan Dosen Pembimbing Utama, dan mencantumkan nama saya, Dosen Pembimbing Utama dan nama-nama lain (jika ada) yang berkontribusi pada makalah.

Pekanbaru, 10 Februari 2026

Yang menyatakan,

(Lailatul Hayani)

KATA PENGANTAR

Alḥamdulillāhi Rabbil ‘Ālamīn. Segala puji dan syukur penulis panjatkan ke hadirat Allah Subḥānahu wa Ta‘ālā, atas segala limpahan rahmat, taufik, dan hidayah-Nya, sehingga penulis dapat menyelesaikan tesis ini, sebagai salah satu syarat untuk menyelesaikan jenjang Pendidikan Magister Terapan pada Program Studi Teknik Komputer Politeknik Caltex Riau. Shalawat serta salam semoga senantiasa tercurah kepada junjungan kita Nabi Muhammad Ṣallallāhu ‘Alaihi Wasallam, beserta keluarga, sahabat, dan seluruh pengikutnya yang setia hingga akhir zaman. Penyusunan tesis ini merupakan proses panjang yang penuh dengan pembelajaran, ujian kesabaran, serta mujahadah ilmiah. Penulis menyadari sepenuhnya bahwa tanpa pertolongan Allah Subḥānahu wa Ta‘ālā tesis ini tidak akan dapat diselesaikan dengan baik. Pada kesempatan ini, penulis juga ingin mengucapkan terima kasih kepada pihak yang telah banyak memberikan bantuan dan dukungan yang tiada terhingga baik secara langsung maupun tidak langsung. Ucapan terima kasih tersebut penulis tujukan kepada:

1. Mama tercinta Elinda Kristin, S.Pd yang menjadi inspirasi dan penyemangat penulis untuk menempuh pendidikan setinggi-tingginya walaupun di usia yang sudah tidak muda lagi, tidak ada kata terlambat untuk belajar.
2. Zinedine Arkha dan Zaidan Alkhalifi anak-anak tercinta, penyemangat hidup, alasan untuk terus memperjuangkan hidup ini. Kakak, adik-adik, keponakan dan keluarga besar yang terus memberikan dukungan sehingga penulis bisa menyelesaikan tesis ini tepat waktu.
3. Bapak Erwin Setyo Nugroho, S.T., M.Eng, selaku pembimbing dan yang memberikan judul tesis ini kepada penulis. Penulis sangat berterimakasih kepada pak Erwin yang telah memberikan Judul tesis ini dan membimbing penulis hingga tesis ini selesai tepat waktu.
4. Bapak Ananda, S.Kom., M.T., Ph.D. selaku pembimbing 1 dan Koordinator Tesis yang selalu memberikan motivasi, bimbingan dan semangat untuk menyelesaikan tesis ini tepat waktu.

5. Bapak Dr. Eng. Yoanda Alim Syahbana, S.T., M.Sc, selaku penguji I, Bapak Dr. Ir. Emansa Hasri Putra, S.T., M.Eng, selaku penguji II dan Ibu Dr. Juni Nurma Sari, S.Kom., M.MT, selaku penguji III yang telah bersedia menguji dan memberikan saran dalam penyempurnaan tesis ini.
6. Dr. Yuni Eka Aggraini, M.Med.Ed.,M.Sc.,SpDVE yang telah banyak membantu dan memberikan saran serta masukan dari segi medis dan dataset sehingga penulis bisa menyelesaikan tesis ini.
7. Seluruh dosen khususnya Program Studi Magister Terapan Teknik Komputer dan seluruh dosen di Politeknik Caltex Riau pada umumnya yang telah memberikan bekal ilmu kepada penulis dalam menyelesaikan penulisan tesis ini.
8. Teman-teman seperjuangan 23MTTKB Program Studi Magister Terapan Teknik Komputer yang telah memberikan semangat dan masukkan dalam penulisan tesis ini.

Penulis sangat menyadari sepenuhnya bahwa laporan ini masih jauh dari sempurna, oleh karena itu segala jenis kritik, saran dan masukan yang membangun sangat penulis harapkan agar dapat memberikan wawasan bagi pembaca dan yang paling utama penulis sendiri.

Pekanbaru, 10 Februari 2026

Yang menyatakan,

(Lailatul Hayani)

ABSTRAK

Keloid merupakan pertumbuhan jaringan parut abnormal yang berdampak pada aspek fisik maupun psikososial pasien. Penilaian keloid saat ini masih mengandalkan metode subjektif seperti *Vancouver Scar Scale* (VSS) atau POSAS yang rentan bias, serta perangkat objektif yang mahal dan terbatas. Untuk mengatasi hal tersebut, penelitian ini mengusulkan sistem evaluasi keloid berbasis citra digital dengan pendekatan *Multi-Task Learning* (MTL) menggunakan CNN-LSTM *end-to-end*. Model yang dikembangkan mampu melakukan tiga tugas sekaligus, yaitu segmentasi area keloid dengan U-Net, pengukuran luasan luka dalam cm² melalui regresi, serta analisis warna (*colorimetry*) berbasis rasio RGB. CNN (ResNet50 pretrained) digunakan sebagai encoder untuk ekstraksi fitur spasial, sedangkan LSTM dimanfaatkan untuk menangkap dinamika temporal dari urutan citra time-series (2 s.d 4 frame per pasien). Dataset citra RGB keloid diproses melalui normalisasi, augmentasi, serta ekstraksi warna dominan dengan K-Means. Evaluasi performa dilakukan menggunakan metrik Dice Score dan IoU untuk segmentasi, MAE dan RMSE untuk regresi luasan, serta MSE untuk analisis warna, dengan pembandingan metode *single-task* dan pengukuran manual (ImageJ). Hasil yang diharapkan adalah peningkatan akurasi segmentasi, error regresi yang lebih rendah, serta analisis warna yang lebih konsisten. Pendekatan ini diharapkan mampu memberikan sistem penilaian keloid yang lebih objektif, akurat, dan efisien, serta berpotensi mendukung implementasi *clinical decision support system* dalam praktik medis.

Kata Kunci

Keloid, Multi-Task Learning, CNN, LSTM, Segmentasi, Regresi Luasan, Colorimetry

ABSTRACT

Keloid are abnormal scar tissue growths that affect both the physical and psychosocial aspects of patients. Current keloid assessment still relies on subjective methods such as the Vancouver Scar Scale (VSS) or POSAS, which are prone to bias, as well as objective devices that are expensive and limited in availability. To address these limitations, this study proposes a digital image-based keloid evaluation system using a Multi-Task Learning (MTL) approach with an end-to-end CNN-LSTM architecture. The developed model is capable of performing three tasks simultaneously: keloid area segmentation using U-Net, wound area measurement in cm^2 through regression, and color analysis (colorimetry) based on RGB ratio. CNN (ResNet50 pretrained) is utilized as an encoder for spatial feature extraction, while LSTM is employed to capture temporal dynamics from time-series image sequences (2 to 4 frames per patient). The RGB keloid image dataset is processed through normalization, augmentation, and dominant color extraction using K-Means. Performance evaluation is conducted using Dice Score and IoU for segmentation, MAE and RMSE for area regression, and MSE for color analysis, with comparisons to single-task methods and manual measurements (ImageJ). The expected outcomes include improved segmentation accuracy, lower regression error, and more consistent color analysis. This approach is anticipated to provide a more objective, accurate, and efficient keloid assessment system, with the potential to support the implementation of clinical decision support systems in medical practice.

Kata Kunci

Keloid, Multi-Task Learning, CNN, LSTM, Segmentation, Area Regression, Colorimetry

DAFTAR ISI

HALAMAN PENGESAHAN	Error! Bookmark not defined.
HALAMAN PERNYATAAN ORISINALITAS.....	viii
HALAMAN KESEPAKATAN PUBLIKASI.....	viii
KATA PENGANTAR	viiiiv
ABSTRAK.....	viii
ABSTRACT	vviii
DAFTAR ISI	viiiiv
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
DAFTAR ISTILAH.....	xixiv
BAB 1 PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Permasalahan	3
1.3 Tujuan.....	3
1.4 Manfaat.....	4
1.4.1 Manfaat Teoritis	4
1.4.2 Manfaat Praktis.....	4
1.5 Batasan Masalah	5
1.6 Sistematika Penulisan	6
BAB 2 KAJIAN PUSTAKA	8
2.1 Teori Penunjang.....	8
2.1.1 Keloid dan Tantangan Penilaiannya	8
2.1.2 Segmentasi dan Citra Digital dalam Kesehatan	8

2.1.3 Analisis Warna (<i>Colorimetry</i>) pada Luka	10
2.1.4 <i>Multi-Task Learning (MTL)</i>	11
2.1.5 <i>Long Short-Term (LSTM)</i> dan Analisis Citra <i>Time-Series</i>	23
2.1.6 <i>Segment Anything Model (SAM)</i> dan <i>Vision Transformer(ViT)</i>	26
2.2 <i>Systematic Literature Review (SLR)</i>	27
2.2.1 Metode SLR.....	27
2.2.2 Hasil SLR	30
2.2.3 Gap Analysis	32
2.2.4 Kesimpulan.....	33
2.3 Penelitian Terkait.....	35
2.3.1 Segmentasi dan Klasifikasi Citra Medis berbasis <i>Deep Learning</i>	35
2.3.2 <i>Colorimetric Analysis</i> pada Luka dan Jaringan Kulit.....	36
2.3.3 Tabel Perbandingan Penelitian Terkait	38
BAB 3 METODOLOGI PENELITIAN	42
3.1 Metodologi Penelitian	42
3.1.1 Pendekatan Penelitian.....	42
3.1.2 Model <i>Multi-Task Learning</i> yang Digunakan	43
3.1.3 Workflow Penelitian.....	44
3.1.4 Alur Kerja Segmentasi Menggunakan SAM.....	46
3.2 Desain Sistem	46
3.2.1 Arsitektur Sistem	46
3.2.2 Representasi Data	51
3.2.3 Persiapan Dataset.....	52
3.2.4 Implementasi Antarmuka Aplikasi.....	53
3.2.5 Strategi Pelatihan.....	56
3.2.6 Spesifikasi Perangkat Keras dan Perangkat Lunak	56

3.2.7 Validasi Klinis	56
3.2.8 Strategi Pembobotan Loss	57
3.3 Rencana Pengujian dan Evaluasi	58
3.3.1 Skema Pengujian	58
3.3.2 Skenario Simulasi	58
3.3.3 Metrik Evaluasi	60
3.3.4 Proses Pengujian dan Analisis Data	61
3.3.5 Pengujian Kinerja MTL dan ImageJ	62
BAB 4 IMPLEMENTASI DAN PENGUJIAN SISTEM.....	63
4.1 Blok Diagram	63
4.1.1 Input Data Citra Luka Keloid	65
4.1.2 Prapemrosesan Data	65
4.1.3 Pembentukan Data Time-Series	69
4.1.4 Implementasi Model CNN-LSTM-MTL.....	73
4.1.5 Proses Inferensi	76
4.1.6 Visualisasi hasil	77
4.2 Hasil Pengujian dan Evaluasi Kuantitatif.....	79
4.2.1 Evaluasi Segmentasi.....	79
4.2.2 Evaluasi Regresi Luasan Luka <i>Single-Task vs Multi-Task Learning</i>	80
4.2.3 Evaluasi Regresi Luasan Luka ImageJ vs MTL	82
4.2.4 Evaluasi Analisis Warna Luka <i>Single-Task vs MTL</i>	85
4.3 Analisis Kualitatif Hasil Sistem	87
4.3.1 Analisis Visual Segmentasi	87
4.3.2 Analisis Perkembangan Luas Luka Keloid	88
4.3.3 Analisis Visual Segmentasi dan Warna Luka Keloid.....	89
4.3.4 Perbandingan <i>Single-Task</i> dan <i>Multi-Task Learning</i>	91

BAB 5 KESIMPULAN DAN SARAN	95
5.1 Kesimpulan.....	95
5.2 Saran	96
DAFTAR PUSTAKA	98

DAFTAR GAMBAR

Gambar 1.1 Contoh bekas luka keloid.....	1
Gambar 1.2 Perbandingan metode penilai keloid subjektif dan objektif	2
Gambar 2.1 Representasi ruang warna	11
Gambar 2.2 Arsitektur umum MTL pada citra medis	19
Gambar 2.3 Skema arsitektur LSTM	25
Gambar 2.4 Diagram alur seleksi literatur SLR pada topik multi-task learning	29
Gambar 2.5 Diagram alur seleksi literatur SLR pada topik Keloid Scars treatment.....	30
Gambar 3.1 Digram Workflow Penelitian.....	45
Gambar 3.2 Diagram Arsitektur CNN-LSTM-MTL.....	47
Gambar 4.1 Blok Diagram	64
Gambar 4.2 Citra medis luka keloid (<i>raw image</i>)	65
Gambar 4.3 Citra medis luka keloid <i>cropping</i>	66
Gambar 4.4 Citra medis luka keloid <i>normalisasi exposure</i>	66
Gambar 4.5 Citra medis luka keloid <i>mask</i>	67
Gambar 4.6 Citra medis luka keloid segmentasi visual.....	68
Gambar 4.7 Citra keloid <i>time series</i>	69
Gambar 4.8 Tampilan utama <i>dashboard</i>	77
Gambar 4.9 Visualisasi perkembangan luasan luka	78
Gambar 4.10 Visualisasi analisis warna	79
Gambar 4.11 Visualisasi dashboard melalui URL http://localhost:8051	79
Gambar 4.12 Pola perbandingan MTL vs ImageJ 4 bulan	82
Gambar 4.13 Pola perbandingan MTL vs ImageJ 4 bulan	84
Gambar 4.14 Pola perbandingan MTL vs ImageJ 4 bulan	85
Gambar 4.15 Perbandingan antara citra asli, <i>ground truth mask</i> , dan <i>predicted mask</i> . 87	
Gambar 4.16 Grafik Perkembangan Luas Luka Keloid	88
Gambar 4.17 Grafik Perkembangan Warna Keloid.....	89
Gambar 4.18 Ringkasan Luasan & <i>Colorimetry</i> Keloid di <i>dashboard</i>	90

DAFTAR TABEL

Tabel 2.1 Tabel Perbandingan Penelitian Terkait	40
Tabel 4.1 Hasil Evaluasi CNN-LSTM-MTL	74
Tabel 4.2 Hasil Evaluasi Segmentasi pada Model CNN-LSTM-MTL	80
Tabel 4.3 Hasil Pengujian Luasan Luka.....	81
Tabel 4.4 Perbandingan Luasan Luka dengan ImageJ 4 bulan	82
Tabel 4.5 Perbandingan Luasan Luka dengan ImageJ 3 bulan	83
Tabel 4.6 Perbandingan Luasan Luka dengan ImageJ 2 bulan	84
Tabel 4.7 Evaluasi Analisis <i>Colorimetry</i>	86
Tabel 4.8 Perbandingan Multi-Task Learning dan Single-Task Learning	91

DAFTAR ISTILAH

Multi-Task Learning (MTL)

Pendekatan pembelajaran mesin yang melatih satu model untuk menyelesaikan beberapa tugas sekaligus (misalnya segmentasi, regresi, klasifikasi). Tujuannya meningkatkan efisiensi dan akurasi melalui berbagi representasi antar-tugas.

Convolutional Neural Network (CNN)

Jenis jaringan saraf tiruan yang efektif dalam mengenali pola spasial pada citra. Digunakan sebagai backbone untuk mengekstraksi fitur pada penelitian citra keloid.

Long Short-Term Memory (LSTM)

Varian Recurrent Neural Network (RNN) yang mampu menangkap informasi urutan atau time-series, sehingga digunakan untuk menganalisis dinamika temporal pada data citra berurutan.

Segmentasi Citra (Image Segmentation)

Proses membagi citra ke dalam beberapa bagian, misalnya memisahkan area keloid dari kulit normal. Output berupa peta piksel (mask) untuk keperluan analisis lebih lanjut.

Regresi Luasan Luka

Proses perhitungan luas area keloid dalam satuan cm^2 dengan metode prediksi numerik berbasis deep learning.

Colorimetry (Analisis Warna)

Analisis kuantitatif warna citra menggunakan model warna (RGB, HSV, CIELAB) untuk menilai kondisi biologis seperti inflamasi atau pigmentasi pada jaringan.

Dice Score

Metrik evaluasi untuk segmentasi citra yang mengukur kesamaan antara hasil prediksi dengan ground truth. Nilai berkisar 0–1, semakin tinggi semakin baik.

Intersection over Union (IoU)

Metrik evaluasi segmentasi yang menghitung perbandingan luas irisan dan gabungan antara hasil prediksi dan ground truth.

Mean Absolute Error (MAE)

Metrik regresi yang menghitung rata-rata selisih absolut antara nilai prediksi dan nilai sebenarnya.

Root Mean Square Error (RMSE)

Metrik regresi yang sensitif terhadap error besar karena menghitung akar dari rata-rata kuadrat error.

Mean Squared Error (MSE)

Metrik evaluasi untuk regresi maupun analisis warna, yang menghitung rata-rata kuadrat selisih antara prediksi dan referensi.

ImageJ

Perangkat lunak analisis citra open-source yang digunakan sebagai metode manual pembandingan dalam validasi hasil model.

K-Means Clustering

Algoritma unsupervised learning yang digunakan untuk menemukan warna dominan pada citra dengan mengelompokkan piksel ke dalam beberapa cluster.

U-Net

Arsitektur CNN khusus untuk segmentasi citra medis yang populer karena kemampuannya menangkap konteks global dan detail lokal.

Candidate Clinical Decision Support System (CDSS)


Sistem pendukung keputusan klinis yang masih berada pada tahap konsep, prototipe, atau proof-of-concept, yang dirancang untuk membantu tenaga medis dalam proses evaluasi dan pengambilan keputusan klinis, namun belum divalidasi atau diterapkan secara penuh dalam praktik klinis.

BAB 1

PENDAHULUAN

1.1 LATAR BELAKANG

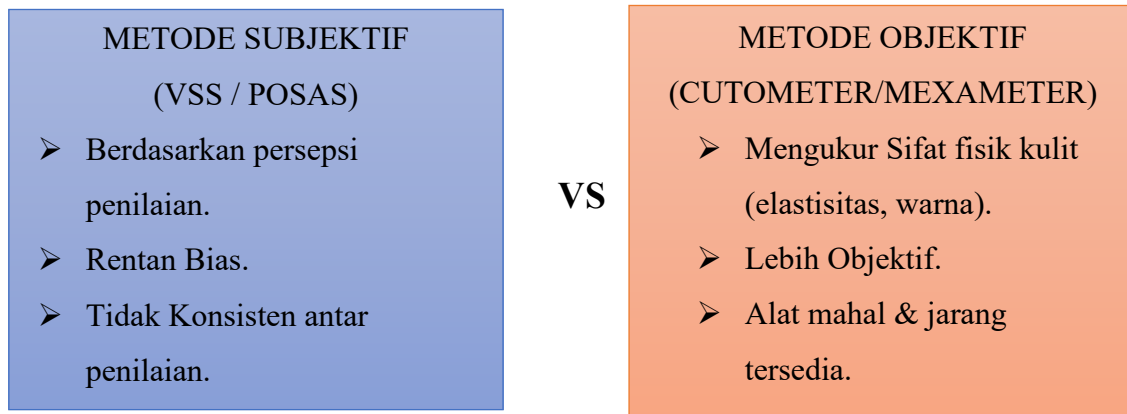
Keloid merupakan bentuk abnormal dari proses penyembuhan luka yang ditandai dengan pertumbuhan jaringan parut berlebih yang melampaui batas luka asal. Kondisi ini dapat menimbulkan rasa nyeri, gatal, keterbatasan gerak, serta gangguan estetika yang berdampak pada kualitas hidup pasien (Ruccia et al., 2021). Penanganan keloid umumnya memerlukan waktu yang lama dan sering kali menghasilkan respons terapi yang tidak konsisten. Oleh karena itu, diperlukan suatu alat atau sistem yang mampu memantau karakteristik keloid secara objektif dan longitudinal (Ruccia et al., 2021). Gambar 1.1 berikut menunjukkan contoh citra keloid pada permukaan kulit, yang menggambarkan karakteristik khas berupa jaringan parut menonjol dengan warna dan tekstur yang berbeda dibandingkan kulit normal di sekitarnya.



Gambar 1.1 Contoh bekas luka keloid (Sumber Ruccia et al., 2021)

Dalam praktik klinis, penilaian keloid masih mengandalkan metode subjektif seperti *Vancouver Scar Scale* (VSS) atau POSAS, yang sangat bergantung pada penilai dan rentan terhadap bias (Abdolahnejad et al., 2024). Selain itu, alat ukur objektif seperti *Cutometer* dan *Mexameter* sering kali mahal dan tidak tersedia luas di fasilitas kesehatan. Perbedaan antara metode subjektif dan objektif dalam penilaian keloid dapat dilihat pada

Gambar 1.2. Ilustrasi ini menunjukkan bagaimana metode subjektif seperti VSS/POSAS masih bergantung pada penilai, sedangkan metode objektif menggunakan alat khusus yang lebih akurat namun terbatas ketersediaannya.



Gambar 1.2 Perbandingan metode penilaian keloid subjektif dan objektif.

Seiring berkembangnya teknologi *Artificial Intelligence* (AI) dan *Computer Vision*, pendekatan berbasis *Convolutional Neural Network* (CNN) telah digunakan untuk mendeteksi dan menganalisis berbagai kelainan kulit termasuk keloid. Namun, sebagian besar penelitian masih menerapkan pendekatan pipeline tradisional, di mana klasifikasi, segmentasi, pengukuran, dan analisis warna dilakukan secara terpisah (Abdolahnejad et al., 2024). Pendekatan ini memiliki sejumlah keterbatasan, seperti kompleksitas alur kerja, kebutuhan terhadap penggabungan modul secara manual, serta kurangnya kemampuan untuk menangkap dinamika temporal perkembangan keloid. Akibatnya, kinerja model dalam memberikan penilaian yang holistik dan akurat menjadi kurang optimal, misalnya hasil segmentasi tidak selalu selaras dengan pengukuran luas luka, analisis warna sering terpisah dari konteks bentuk luka, serta proses pemantauan longitudinal menjadi terputus-putus. Hal ini membuat model sulit memberikan gambaran perkembangan keloid yang konsisten dan komprehensif.

Untuk mengatasi keterbatasan tersebut, penelitian ini mengusulkan penggunaan pendekatan *Multi-Task Learning* (MTL) berbasis CNN dan *Long Short-Term Memory* (LSTM). Pendekatan ini memungkinkan pemrosesan *time-series* citra keloid secara *end-to-end* dalam satu arsitektur model, dengan keluaran simultan berupa segmentasi lesi, pengukuran luas luka, dan analisis warna (*colorimetry*). Dengan demikian, sistem ini diharapkan mampu meningkatkan kinerja model dalam memberikan penilaian yang lebih

objektif, akurat, dan efisien terhadap perkembangan keloid dari waktu ke waktu (Ruccia et al., 2021; Abdolahnejad et al., 2024).

1.2 PERMASALAHAN

Berdasarkan uraian latar belakang di atas, terdapat beberapa masalah yang diangkat dalam penelitian ini, yaitu:

1. Bagaimana mengembangkan arsitektur end-to-end berbasis *Multi-Task Learning* (MTL) dengan integrasi CNN untuk ekstraksi fitur spasial dan LSTM untuk pemodelan temporal, sehingga mampu melakukan segmentasi, pengukuran luasan, dan analisis warna (*colorimetry*) pada scar keloid secara objektif dan akurat dalam satu alur kerja?
2. Bagaimana mengevaluasi performa model tersebut dalam memantau perubahan karakteristik keloid secara longitudinal pada data citra *time-series*, serta menilai akurasi prediksi yang dihasilkan dalam konteks klinis?

1.3 TUJUAN

Penelitian ini bertujuan untuk mengembangkan model analisis citra medis berbasis *Multi-Task Learning* (MTL) dengan kombinasi *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) yang mampu melakukan segmentasi area keloid, pengukuran luasan luka, dan analisis warna jaringan secara simultan dalam satu kerangka kerja *end-to-end*. Secara khusus, penelitian ini bertujuan untuk:

1. Membangun model CNN-LSTM berbasis MTL yang dapat memproses citra RGB keloid secara *time-series* guna mengenali perubahan morfologi dan warna jaringan dari waktu ke waktu.
2. Mengembangkan sistem otomatis untuk memantau proses penyembuhan keloid pasien, dengan cara mengukur perubahan area luka (dalam cm²) dan analisis warna (rasio RGB) sebagai indikator objektif fase penyembuhan seperti inflamasi, maturasi, atau hiperpigmentasi.

3. Menguji akurasi dan efisiensi model yang dikembangkan dibandingkan metode konvensional (seperti pengukuran manual menggunakan ImageJ), baik dari sisi hasil segmentasi, estimasi luas luka, maupun kecepatan pemrosesan.
4. Menyediakan *proof-of-concept* dalam bentuk aplikasi berbasis web (Dash Application) yang dapat digunakan oleh dokter atau peneliti untuk melakukan evaluasi visual dan kuantitatif terhadap progres penyembuhan keloid secara real-time.

Dengan pencapaian tujuan tersebut, penelitian ini diharapkan dapat memberikan kontribusi pada bidang analisis citra medis dan dermatologi digital, khususnya dalam pemantauan penyembuhan luka keloid secara non-invasif, objektif, dan efisien.

1.4 MANFAAT

Penelitian ini diharapkan memberikan manfaat teoritis dan praktis dalam pengembangan model *Multi-Task Learning* (MTL) berbasis CNN dan LSTM untuk penilaian *scar* keloid.

1.4.1 Manfaat Teoritis

1. Menambah kajian dalam bidang *deep learning* medis, khususnya penerapan multi-task learning dan temporal modeling pada analisis citra kulit.
2. Mengembangkan pendekatan *end-to-end* yang mampu menggabungkan segmentasi, pengukuran luasan, dan analisis warna dalam satu arsitektur, sehingga dapat menjadi referensi bagi penelitian sejenis.
3. Membuka peluang penelitian lebih lanjut terkait integrasi model *deep learning* dengan sistem klinis untuk pemantauan luka secara longitudinal.

1.4.2 Manfaat Praktis

1. Memberikan solusi alternatif berbasis citra digital yang objektif, konsisten, dan praktis untuk memantau perkembangan keloid.

2. Membantu tenaga medis dalam mengevaluasi kondisi keloid secara lebih akurat tanpa bergantung pada alat ukur mahal atau metode subjektif.
3. Mendukung proses pengambilan keputusan klinis dengan menyediakan data yang terukur dari waktu ke waktu.
4. Berpotensi diterapkan dalam sistem pendukung keputusan medis (*clinical decision support system*) untuk pemantauan luka pada layanan kesehatan.

Penelitian ini diharapkan dapat menjadi solusi optimal dalam penilaian dan pemantauan *scar* keloid berbasis *deep learning*, dengan keseimbangan antara objektivitas, akurasi, dan kemudahan penerapan di lingkungan klinis.

1.5 BATASAN MASALAH

Agar penelitian ini tetap fokus dan memiliki ruang lingkup yang jelas, beberapa batasan berikut diterapkan dalam studi ini:

1. Data yang digunakan berupa citra digital 2D berformat RGB dengan penanda ukuran (*fiducial marker*) untuk kalibrasi skala. Dataset terdiri dari *time-series* citra keloid dengan 2 s.d 4 citra per pasien pada interval waktu tetap.
2. Model yang dikembangkan adalah arsitektur *Multi-Task Learning* (MTL) berbasis CNN-LSTM yang dirancang untuk melakukan segmentasi, pengukuran luasan, dan analisis warna secara simultan dalam satu alur (*end-to-end pipeline*).
3. Pra-pemrosesan citra dilakukan menggunakan ImageJ untuk pengukuran dasar (*ground truth, cropping*, area luka, serta ekstraksi warna), dan dapat didukung oleh OpenCV dalam tahap otomatisasi coding agar lebih terintegrasi dengan *framework deep learning*.
4. Analisis warna pada penelitian ini dibatasi pada pengukuran karakteristik warna luka keloid menggunakan ruang warna *CIELAB* (L, a, b^*)** pada area luka hasil segmentasi. Analisis difokuskan pada komponen L^* sebagai indikator tingkat kecerahan atau pigmentasi jaringan, serta komponen a^* sebagai indikator eritema (kemerahan), yang diekstraksi secara kuantitatif dari area luka untuk mengamati perubahan karakteristik warna secara longitudinal.

5. Model tidak mengukur ketinggian atau volume keloid secara fisik karena keterbatasan perangkat (citra 2D).
6. Evaluasi performa model dilakukan secara *offline* dengan menggunakan metrik segmentasi berupa Dice Score, metrik regresi luasan luka berupa *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE), serta metrik analisis warna berupa Mean Squared Error (MSE) pada komponen warna CIELAB, khususnya L* (pigmentasi) dan a* (eritema), tanpa implementasi uji klinis langsung. Evaluasi dilakukan secara offline tanpa implementasi uji klinis langsung.

1.6 SISTEMATIKA PENULISAN

Bab 1 Pendahuluan

Bab ini menjelaskan latar belakang dari penelitian, perumusan masalah, tujuan, manfaat, batasan penelitian, serta sistematika penulisan yang menjadi dasar arah dan ruang lingkup penelitian.

Bab 2 Kajian Pustaka

Bab ini berisi kajian literatur dan teori-teori yang mendukung penelitian, termasuk ulasan mengenai keloid, metode penilaian luka, teknik *computer vision*, serta pendekatan *deep learning* seperti CNN, LSTM, dan *Multi-Task Learning*. Selain itu, bab ini juga membahas hasil penelitian sebelumnya serta celah penelitian (*research gap*) yang menjadi dasar kontribusi dari penelitian ini.

Bab 3 Metodologi Penelitian

Bab ini menjelaskan secara rinci metode penelitian yang digunakan, meliputi desain model *deep learning*, arsitektur CNN-LSTM berbasis *Multi-Task Learning*, pengumpulan dan pra-pemrosesan data citra keloid, serta teknik evaluasi performa model berdasarkan metrik segmentasi, regresi, dan analisis warna.

Bab 4 Implementasi dan Pengujian Sistem

Bab ini membahas implementasi sistem yang telah dirancang pada tahap sebelumnya serta pengujian kinerja sistem berdasarkan data yang digunakan dalam penelitian. Pembahasan mencakup tahapan implementasi metode CNN–LSTM–Multi-Task Learning pada analisis luka keloid, pengujian fungsionalitas sistem, serta evaluasi kinerja model dari aspek segmentasi, estimasi luasan luka, dan analisis warna jaringan.

Bab 5 Kesimpulan dan Saran

Bab ini memuat kesimpulan yang diperoleh berdasarkan hasil implementasi dan pengujian sistem yang telah dilakukan pada penelitian ini. Selain itu, bab ini juga menyajikan saran yang ditujukan untuk pengembangan penelitian selanjutnya, khususnya terkait peningkatan metode, kualitas data, dan penyempurnaan sistem pemantauan luka keloid berbasis analisis citra medis.

BAB 2

KAJIAN PUSTAKA

Bab ini membahas teori-teori penunjang yang berkaitan dengan penelitian berjudul *Segmentasi, Pengukuran Luasan, dan Colorimetry pada Scar Keloid Menggunakan Multi-Task Learning Berbasis CNN dan LSTM*, dilanjutkan dengan *systematic literature review* (SLR) yang menelaah penelitian-penelitian terdahulu. Kajian ini juga memaparkan penelitian terkait yang relevan dengan topik penelitian.

2.1 TEORI PENUNJANG

2.1.1 Keloid dan Tantangan Penilaiannya

Keloid merupakan bentuk pertumbuhan jaringan parut abnormal yang terjadi akibat penyembuhan luka yang tidak sempurna. Secara histopatologi, keloid ditandai oleh proliferasi fibroblas dan sintesis kolagen yang berlebihan, bahkan meluas melampaui batas luka asal (Ruccia et al., 2021). Tidak hanya berdampak secara fisik seperti rasa nyeri, gatal, dan keterbatasan gerak, keloid juga memberi pengaruh signifikan terhadap kualitas hidup penderitanya secara psikososial dan estetika.

Penilaian terhadap kondisi keloid saat ini masih didominasi oleh metode subjektif seperti *Vancouver Scar Scale* (VSS) dan *Patient and Observer Scar Assessment Scale* (POSAS). Kedua skala ini dinilai praktis, namun bergantung pada persepsi penilai sehingga kurang konsisten dan rentan terhadap bias antar pengamat (Abdolahnejad et al., 2024). Selain itu, meskipun terdapat perangkat objektif seperti Cutometer dan Mexameter, alat-alat tersebut umumnya mahal dan tidak tersedia luas, sehingga keterbatasan ini menjadi salah satu pendorong dalam pengembangan sistem evaluasi digital berbasis citra.

2.1.2 Segmentasi Citra Digital dalam Kesehatan

Segmentasi citra merupakan salah satu tahap fundamental dalam pengolahan citra digital. Secara umum, segmentasi didefinisikan sebagai proses membagi suatu citra

menjadi beberapa region atau area homogen yang memiliki karakteristik serupa, sehingga objek penting dapat dipisahkan dari latar belakang (Gonzalez & Woods, 2018). Tujuan utama segmentasi adalah untuk memudahkan analisis lebih lanjut, seperti pengukuran ukuran, bentuk, tekstur, dan warna dari objek yang diamati. Secara teori, terdapat beberapa pendekatan dasar segmentasi citra, antara lain:

1. Berbasis Ambang (*Thresholding*): memisahkan objek dan latar berdasarkan intensitas piksel atau nilai ambang tertentu.
2. Berbasis Deteksi Tepi (*Edge-based*): mendeteksi batas objek menggunakan operator gradien, seperti Sobel, Canny, atau Laplacian.
3. Berbasis Region (*Region-based*): mengelompokkan piksel yang homogen berdasarkan kriteria kesamaan tertentu, misalnya *region growing* atau *region splitting and merging*.
4. Berbasis *Clustering*: menggunakan metode unsupervised seperti *K-Means* atau *Fuzzy C-Means* untuk membagi piksel menjadi beberapa cluster sesuai karakteristik warna atau intensitas.

Dalam konteks citra medis, segmentasi menjadi langkah krusial untuk mengidentifikasi area patologis, seperti tumor, luka, atau jaringan parut keloid. Akurasi segmentasi akan sangat memengaruhi tahap ekstraksi fitur dan analisis selanjutnya, misalnya pengukuran luasan atau analisis warna.


Seiring berkembangnya teknologi, algoritma *Convolutional Neural Network* (CNN) telah menjadi pendekatan populer dalam segmentasi medis karena kemampuannya menangkap pola spasial dan tekstur. Arsitektur seperti U-Net (Ronneberger et al., 2015), ResUNet, dan Attention U-Net terbukti unggul dalam memisahkan objek medis dari latar belakang dengan tingkat akurasi tinggi. U-Net, misalnya, dirancang khusus untuk segmentasi citra medis dengan memanfaatkan mekanisme *encoder-decoder* serta *skip connection* untuk mempertahankan detail spasial. Berbagai penelitian kemudian memodifikasi U-Net dengan *residual block*, *pretrained backbone* (ResNet, EfficientNet, DenseNet), dan mekanisme perhatian (*attention mechanism*) untuk meningkatkan performa segmentasi (Chen et al., 2020).

2.1.3 Analisis Warna (Colorimetry) pada Luka

Colorimetry adalah proses pengukuran dan analisis warna dalam citra digital yang digunakan untuk menilai karakteristik jaringan seperti kadar melanin, hemoglobin, dan inflamasi pada luka atau scar. Dalam evaluasi keloid, warna memiliki arti klinis penting karena perubahan warna dapat mengindikasikan tingkat peradangan dan proses penyembuhan. Warna citra biasanya direpresentasikan dalam beberapa ruang warna, di antaranya:

- RGB (*Red, Green, Blue*): representasi warna berdasarkan kombinasi tiga komponen dasar cahaya.
- HSV (*Hue, Saturation, Value*): lebih mendekati persepsi manusia, dengan *hue* mewakili jenis warna, *saturation* tingkat kejenuhan, dan *value* tingkat kecerahan.
- CIELAB: ruang warna yang dirancang menyerupai persepsi visual manusia, terdiri dari komponen *L* (kecerahan), *a* (hijau-merah), dan *b* (biru-kuning).

Untuk mengekstraksi warna dominan dari citra luka, metode seperti *K-Means Clustering* atau *Mean Shift Clustering* dapat digunakan untuk mengelompokkan piksel ke dalam sejumlah segmen warna yang signifikan. Dalam studi Ruccia et al. (2021), analisis melanin dan erythema dari citra keloid menunjukkan potensi sebagai indikator respons terhadap terapi steroid intralesi. Untuk memperjelas konsep representasi ruang warna yang digunakan dalam analisis citra. Menurut Berasarte et al. (2025), ruang warna seperti RGB, HSV, dan CIELAB merupakan representasi matematis dari warna yang banyak digunakan dalam *digital image colorimetry*. Model RGB mendeskripsikan warna berdasarkan intensitas merah, hijau, dan biru, sedangkan HSV lebih sesuai untuk mengekspresikan persepsi manusia terhadap warna melalui dimensi *hue*, *saturation*, dan *value*. Sementara itu, CIELAB dianggap lebih unggul dalam analisis warna kuantitatif karena sifatnya yang lebih linear terhadap persepsi visual manusia. Gambar 2.2 menyajikan ilustrasi ruang warna (RGB, HSV, dan CIELAB) beserta penerapannya pada citra keloid.



Gambar 2.1. Representasi ruang warna (RGB, HSV, CIELAB) pada citra keloid
(Sumber Berasarte et al., 2025).

2.1.4 Multi-Task Learning (MTL)

Multi-Task Learning (MTL) merupakan pendekatan pembelajaran mesin di mana sebuah model dilatih untuk menyelesaikan beberapa tugas secara bersamaan, dengan tujuan memanfaatkan keterkaitan antar tugas untuk meningkatkan performa keseluruhan (Caruana, 1997). Ide dasarnya adalah *inductive transfer*, yaitu pengetahuan yang diperoleh dari satu tugas dapat membantu tugas lain melalui representasi bersama (*shared representation*).

1. Kategori Utama dalam MTL

Menurut Zhang dan Yang (2018), *Multi-Task Learning* (MTL) dapat dibedakan menjadi dua kategori utama berdasarkan cara berbagi parameter antartugas, yaitu *Hard Parameter Sharing* dan *Soft Parameter Sharing*.

Kedua pendekatan ini memiliki tujuan yang sama, yaitu memungkinkan beberapa tugas (tasks) saling berbagi pengetahuan untuk meningkatkan generalisasi model, namun mekanismenya berbeda secara struktural.

a. *Hard Parameter Sharing*

Pada *hard parameter sharing*, beberapa *task* berbagi lapisan dasar (*shared layers*) yang sama, sementara hanya lapisan akhir (*task-specific layers*) yang berbeda. Artinya, bobot pada bagian awal jaringan digunakan secara bersama oleh semua tugas, sehingga model dapat mengekstraksi fitur umum (*shared representation*) yang bermanfaat bagi seluruh tugas.

Formula umum fungsi loss total dituliskan sebagai:

$$\mathcal{L}_{total} = \sum_{i=1}^T \lambda_i \mathcal{L}_i \quad \dots (1)$$

dengan:

- $\mathcal{L}_i$: fungsi loss dari tugas ke-i,
- λ_i : bobot relatif dari masing-masing tugas,
- T: jumlah total tugas dalam model MTL.

Sebagai contoh, untuk dua tugas seperti segmentasi ($\mathcal{L}_{seg}$) dengan $\mathcal{L}_i$ dan klasifikasi $\mathcal{L}_{cls}$, maka:

$$\mathcal{L}_{total} = \lambda_{seg} \mathcal{L}_{seg} + \lambda_{cls} \mathcal{L}_{cls} \quad \dots (2)$$

Jika $\lambda_{seg} = 0.6$ dan $\lambda_{cls} = 0.4$, maka model lebih menekankan kualitas segmentasi dibanding klasifikasi.

Keunggulan *hard parameter sharing*:

- Mengurangi risiko *overfitting* karena parameter bersama mengurangi kompleksitas total model.
- Efisien secara komputasi dan memori karena sebagian besar parameter dibagi bersama.

Kelemahannya:

- Kurang fleksibel jika antar-tugas memiliki karakteristik yang sangat berbeda.
- Satu tugas bisa mendominasi pembelajaran dan mengganggu performa tugas lainnya (*negative transfer*).

b. Soft Parameter Sharing

Sebaliknya, pada *soft parameter sharing*, setiap tugas memiliki arsitektur model terpisah, namun hubungan antar model diatur melalui regularisasi jarak antar parameter. Dengan kata lain, bobot model yang berbeda dipaksa untuk tidak terlalu jauh satu sama lain agar tetap belajar representasi yang mirip.

Rumus umum regularisasi *soft parameter sharing* adalah:

$$\mathcal{L}_{total} = \sum_{i=1}^T \mathcal{L}_i + \mu \sum_{i \neq j} \|\theta_i - \theta_j\|^2 \quad \dots (3)$$

Keterangan:

- $\mathcal{L}_i$: fungsi loss dari tugas ke- i
- θ_i : parameter (bobot) model untuk tugas ke- i
- μ : koefisien regularisasi untuk mengontrol jarak antar-parameter
- T : jumlah total tugas dalam MTL $\|\theta_i - \theta_j\|^2$
- $\|\theta_i - \theta_j\|^2$: penalti jarak parameter antar model tugas ke- i dan ke- j , agar tetap belajar representasi yang mirip

Contoh Implementasi dari jurnal breast ultrasound, 2023. yang menggabungkan tugas segmentasi (Dice Loss) dan klasifikasi (Cross-Entropy Loss) dalam satu framework MTL. Formula loss gabungan yang dipakai:

$$\mathcal{L}_{total} = \alpha \times \mathcal{L}_{Dice} + \beta \times \mathcal{L}_{CE} \quad \dots (4)$$

Keterangan:

- $\mathcal{L}_{Dice}$: fungsi *Dice Loss* untuk tugas segmentasi
- $\mathcal{L}_{CE}$: *Cross-Entropy Loss* untuk tugas klasifikasi
- α, β : bobot relatif yang menyeimbangkan kontribusi masing-masing tugas

Sebagai ilustrasi, jika hasil training menunjukkan Dice Loss = 0.25 dan Cross Entropy Loss = 0.35, dengan bobot $\alpha = 0.7$ dan $\beta = 0.3$:

$$\mathcal{L}_{total} = 0.7(0.25) + 0.3(0.35) = 0.175 + 0.105 = 0.280$$

Pendekatan ini lebih fleksibel, namun memerlukan sumber daya komputasi yang lebih besar karena setiap tugas memiliki model tersendiri.

c. Relevansi untuk penelitian ini

Formula Dalam penelitian ini, digunakan pendekatan Hard Parameter Sharing, di mana lapisan CNN digunakan bersama untuk mengekstraksi fitur spasial dari citra keloid, sedangkan lapisan LSTM dan output head bersifat spesifik untuk setiap tugas, yaitu:

- Segmentasi luka (Loss: Dice Score)
- Pengukuran luasan area (Loss: MAE/RMSE)
- Analisis warna (*Colorimetry*, Loss: MSE pada rasio RGB)

Formulasi *multi-task loss function* yang digunakan adalah:

$$\mathcal{L}_{total} = \lambda_1 \times \mathcal{L}_{Dice} + \lambda_2 \times \mathcal{L}_{Reg} + \lambda_3 \times \mathcal{L}_{Color} \quad \dots (5)$$

dengan:

- $\mathcal{L}_{Dice}$: *Dice Loss* untuk segmentasi area keloid,
- $\mathcal{L}_{Reg}$: *Mean Absolute Error (MAE)* untuk regresi luasan luka,

- $\mathcal{L}_{Color}$: *Mean Squared Error (MSE)* untuk analisis warna RGB,
- $\lambda_1, \lambda_2, \lambda_3$: bobot relatif tiap tugas.

Pembobotan loss digunakan untuk menjaga keseimbangan antar-tugas agar tidak terjadi *task domination*. Dalam penelitian ini, pembobotan diatur secara dinamis dengan metode *uncertainty weighting* (Kendall et al., 2018), sehingga setiap tugas berkontribusi optimal terhadap pembelajaran keseluruhan.

Sebagai contoh, jika $\mathcal{L}_{Dice} = 0.2$, $\mathcal{L}_{Regresi} = 15$, $\mathcal{L}_{Color} = 0.05$, dengan $\lambda_1 = 0.5$, $\lambda_2 = 0.3$, $\lambda_3 = 0.2$:

$$\mathcal{L}_{total} = 0.5(0.2) + 0.3(15) + 0.2(0.05) = 0.1 + 4.5 + 0.01 = 4.61$$

Pendekatan *hard sharing* ini dipilih karena:

- Ketiga tugas (*segmentasi, regresi, colorimetry*) berasal dari domain visual yang sama (citra RGB keloid).
- Diperlukan efisiensi komputasi agar model dapat berjalan *end-to-end* dalam satu arsitektur CNN–LSTM tanpa memerlukan pelatihan terpisah.
- Feature sharing antar-tugas diharapkan meningkatkan konsistensi spasial-temporal hasil analisis.

2. Arsitektur Umum Multi-Task Learning (MTL) pada Citra Medis

Dalam ranah *medical image analysis*, pendekatan *Multi-Task Learning* (MTL) umumnya dibangun dengan arsitektur *end-to-end* yang terdiri dari tiga komponen utama:

a. Backbone / Feature Extractor

- Umumnya berupa *Convolutional Neural Network* (CNN) (misalnya ResNet, U-Net encoder) atau *Transformer* (misalnya Swin Transformer, Vision Transformer) yang berfungsi mengekstraksi representasi spasial dari citra medis (Ruder, 2017; Zhang & Yang, 2018).
- Backbone ini berperan sebagai *shared representation layer* yang digunakan bersama oleh seluruh tugas (*hard parameter sharing*).

b. Task-Specific Heads

Setelah representasi bersama diperoleh, jaringan bercabang menjadi beberapa *task heads* sesuai kebutuhan:

- *Segmentation Head*: menghasilkan peta piksel (*segmentation mask*) untuk memisahkan area lesi vs non-lesi (Ronneberger et al., 2015; Zhang et al., 2023).
- *Regression Head*: memprediksi parameter kuantitatif, misalnya luas lesi, volume jaringan, atau metrik klinis tertentu. Biasanya terdiri dari lapisan *fully-connected* (FC) yang memproses vektor fitur (Cai et al., 2020).
- *Classification / Colorimetry Head*: mengestimasi label klinis (jinak vs ganas) atau kuantifikasi warna (misalnya rasio RGB/CIELAB) yang relevan dengan diagnosis (Liu et al., 2019; Berasarte et al., 2025).

c. Loss Function Gabungan

- Fungsi kerugian dari tiap head digabungkan dalam bentuk *weighted sum*:

$$\mathcal{L}_{total} = \lambda_{seg} \times \mathcal{L}_{seg} + \lambda_{reg} \times \mathcal{L}_{reg} + \lambda_{cls} \times \mathcal{L}_{cls} \dots (6)$$

- Bobot ditentukan untuk menyeimbangkan kepentingan tiap tugas (Kendall et al., 2018).
- Misalnya, *Dice Loss* digunakan untuk segmentasi, MAE/RMSE untuk regresi, dan *Cross-Entropy* / MSE untuk klasifikasi atau *Colorimetry*.

Arsitektur ini memungkinkan satu input citra medis menghasilkan keluaran multi-dimensi (mask segmentasi, nilai kuantitatif, serta label/rasio warna), sehingga lebih efisien dibandingkan pendekatan terpisah. Selain itu, MTL terbukti meningkatkan *generalization performance* karena representasi bersama mendorong model untuk belajar fitur yang lebih kaya (Cai et al., 2020; Zhang et al., 2023).

3. Keunggulan dan Tantangan Multi-Task Learning dalam Citra Medis

Pendekatan Multi-Task Learning (MTL) memiliki sejumlah keunggulan yang membuatnya semakin populer dalam analisis citra medis. Salah satu keuntungan utama adalah efisiensi parameter. Dengan menggunakan satu model yang dapat menyelesaikan beberapa tugas sekaligus, MTL mampu menggantikan pipeline terpisah yang biasanya membutuhkan model berbeda untuk segmentasi, klasifikasi, maupun regresi. Hal ini tidak hanya mengurangi kompleksitas komputasi, tetapi juga menghemat sumber daya pelatihan. Selain itu, MTL memberikan peningkatan kemampuan generalisasi. Representasi fitur yang dibagi di antara beberapa tugas cenderung lebih kaya dan bermakna dibandingkan model tugas tunggal, sehingga dapat mengurangi bias serta meningkatkan robustnes saat diuji pada data baru. Keunggulan lain yang sering disorot adalah reduksi propagasi error. Pada pendekatan tradisional yang terpisah, kesalahan pada tahap awal, seperti segmentasi, akan terbawa ke modul berikutnya. Sebaliknya, dalam MTL semua komponen dilatih secara *end-to-end*, sehingga kesalahan pada satu tugas dapat diminimalkan melalui pembelajaran bersama.

Meskipun demikian, MTL juga menghadapi sejumlah tantangan metodologis. Salah satu permasalahan umum adalah *task imbalance*, di mana beberapa tugas cenderung lebih dominan dalam proses pelatihan sehingga menurunkan kinerja tugas lain. Tantangan lain adalah penentuan bobot relatif antar fungsi *loss*. Sampai saat ini, tidak ada formula universal yang optimal, dan pemilihan bobot relatif (λ) untuk tiap tugas masih menjadi topik penelitian aktif. Selain itu, terdapat risiko *negative transfer*, yaitu kondisi ketika dua tugas yang dilatih bersama tidak saling mendukung, bahkan justru menurunkan performa keseluruhan sistem. Oleh karena itu, perancangan arsitektur MTL dalam citra medis harus mempertimbangkan keterkaitan antar tugas secara hati-hati.

Dalam penelitian ini, beberapa strategi diterapkan untuk mengantisipasi permasalahan tersebut, antara lain:

1. *Uncertainty Weighting* (Kendall et al., 2018): digunakan untuk menyesuaikan bobot loss tiap tugas secara dinamis berdasarkan tingkat ketidakpastian (*task*


uncertainty) selama pelatihan. Pendekatan ini efektif mengurangi *task imbalance* karena bobot disesuaikan otomatis sesuai kesulitan masing-masing tugas.

2. *Feature Sharing Terbatas (Hard Parameter Sharing)*: hanya lapisan encoder (CNN-LSTM) yang dibagikan antar-tugas, sementara setiap cabang output memiliki *task-specific layer* sendiri. Hal ini mencegah terjadinya *negative transfer* akibat interferensi antar-representasi.
3. *Monitoring Loss Curves Per Tugas*: selama pelatihan, setiap fungsi loss dimonitor secara terpisah untuk mendeteksi dominasi satu tugas terhadap yang lain. Penyesuaian bobot atau *learning rate scheduling* dilakukan jika perbedaan konvergensi terlalu besar.
4. *Cross-Task Consistency Loss* (adaptasi dari He et al., 2021): diterapkan untuk memastikan hasil regresi luas luka konsisten dengan area segmentasi yang dihasilkan, sehingga antar-tugas saling memperkuat.

Dengan kombinasi strategi tersebut, model diharapkan mampu mempertahankan keseimbangan antar-tugas dan menghindari efek *negative transfer*, sekaligus meningkatkan stabilitas pembelajaran *multi-task* secara keseluruhan.

Setelah berbagai tantangan metodologis tersebut diantisipasi. MTL telah banyak diterapkan secara luas dalam domain medis dengan hasil yang menjanjikan. Sebagai contoh, penelitian Ronneberger et al. (2015) dan Chen et al. (2020) menunjukkan bahwa MTL mampu meningkatkan akurasi segmentasi sekaligus prediksi *outcome* klinis. Dalam dermatologi, Abdolahnejad et al. (2024) melaporkan bahwa integrasi segmentasi, klasifikasi, dan analisis warna menghasilkan sistem pemantauan keloid yang lebih efisien dibanding pendekatan terpisah.

Pendekatan umum MTL pada citra medis ditunjukkan pada Gambar 2.3, dengan satu *shared encoder* dan beberapa *task-specific heads* untuk segmentasi, regresi, dan analisis warna.



Gambar 2.2. Arsitektur umum MTL pada citra medis
(Sumber Liu et al., 2019; Zhang & Yang, 2018).

Gambar 2.3 memperlihatkan bagaimana citra masukan (*input image*) diproses melalui *shared encoder* berbasis CNN untuk menghasilkan representasi fitur yang digunakan secara bersama. Fitur ini kemudian diteruskan ke tiga cabang tugas spesifik (*heads*), yaitu:

1. *Segmentation Head* untuk mendeteksi area luka,
2. *Regression Head* untuk menghitung luas luka, dan
3. *Colorimetry Head* untuk menganalisis warna jaringan.

Struktur ini menggambarkan prinsip *hard parameter sharing* yang digunakan juga dalam penelitian ini, di mana satu encoder digunakan untuk mendukung beberapa tugas sekaligus secara efisien dan konsisten.

4. Konsep Multi-Task Learning pada Analisis Citra Medis

Pendekatan *Multi-Task Learning* (MTL) dalam analisis citra medis telah menunjukkan efektivitas tinggi dalam meningkatkan akurasi model dengan memanfaatkan *feature sharing* antar-tugas yang saling berkaitan. Dalam konteks penelitian ini, tiga studi utama dijadikan dasar pengembangan model CNN-LSTM-MTL yang mencakup tugas segmentasi, regresi luasan luka, dan analisis warna (*colorimetry*):

1. MTL untuk Segmentasi berdasarkan *Diagnosis of Esophageal Lesions by Multi-Classification and Segmentation Using an Improved Multi-Task Deep Learning Mode*.

Penelitian oleh Tang et al. (2022) mengusulkan model *Improved Multi-Task Deep Learning (MTDL)* yang menggabungkan segmentasi dan klasifikasi lesi esofagus dalam satu arsitektur terpadu. Model ini menggunakan ResNet50 sebagai *shared encoder* untuk mengekstraksi fitur spasial dari citra endoskopi, yang kemudian dibagi menjadi dua cabang output: segmentasi area lesi dan klasifikasi jenis kelainan jaringan. Pendekatan Tang et al. menunjukkan bahwa pembelajaran lintas-tugas (*cross-task learning*) antara segmentasi dan klasifikasi dapat meningkatkan ketepatan deteksi tepi (*boundary accuracy*) serta konsistensi hasil segmentasi. Hal ini dicapai melalui tiga mekanisme utama:

- *Shared Feature Representation*: fitur hasil ekstraksi ResNet50 digunakan bersama oleh kedua cabang tugas, memungkinkan model menangkap korelasi spasial dan semantik antar-lesi.
- *Improved U-Net Decoder*: cabang segmentasi menggunakan struktur *U-Net enhanced* dengan *skip connections* yang dioptimalkan untuk mempertahankan detail spasial pada area kecil.
- *Joint Optimization Strategy*: fungsi *loss* gabungan digunakan untuk menyeimbangkan pembelajaran kedua tugas, di mana hasil klasifikasi memberikan umpan balik terhadap segmentasi (*feedback refinement*) melalui pembobotan dinamis.

Eksperimen mereka menunjukkan peningkatan akurasi segmentasi sebesar 2–4% dibandingkan model single-task U-Net, serta perbaikan signifikan dalam konsistensi prediksi antar-citra. Dalam konteks penelitian ini, prinsip dari Tang et al. diadaptasi untuk merancang cabang segmentasi pada model CNN-LSTM-MTL, dengan beberapa modifikasi penting:

- Backbone ResNet50 pretrained tetap digunakan sebagai encoder utama untuk memanfaatkan kekuatan representasi spasial yang telah terbukti.
- Cabang segmentasi dikembangkan menggunakan decoder berbasis U-Net untuk menghasilkan *binary mask* area keloid dengan delineasi yang lebih presisi.

- Hasil segmentasi ini menjadi dasar bagi dua tugas lain dalam arsitektur *multi-task*, yaitu regresi luasan luka dan analisis warna (colorimetry), sehingga ketiga tugas saling mendukung dalam satu model *end-to-end*. Pendekatan ini memastikan bahwa model tidak hanya mampu mengenali batas luka secara akurat, tetapi juga mampu memberikan estimasi kuantitatif (luasan) dan karakterisasi warna jaringan yang relevan secara klinis.

2. MTL untuk Regresi Luas dan Boundary Awareness berdasarkan *HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images*

He et al. (2021) mengusulkan HF-UNet, sebuah arsitektur Multi-Task U-Net yang memperkenalkan mekanisme *Hierarchical Feature Sharing* dan *Task Consistency Learning (TCL)* untuk meningkatkan akurasi segmentasi prostat pada citra CT. Dalam pendekatan ini, dua tugas utama segmentasi dan delineasi batas organ dipelajari secara bersamaan melalui blok atensi (*attention block*) di setiap level hierarki *encoder-decoder*.

Metodologi utama HF-UNet mencakup:

- *Hierarchical Inter-Task Relevance*: fitur dari setiap tugas dipertukarkan antar-layer melalui *task-interaction modules* untuk meningkatkan konsistensi prediksi.
- *Task Consistency Learning (TCL)*: *loss* tambahan digunakan untuk memastikan kesesuaian antara hasil segmentasi dan prediksi batas objek.
- *Joint Optimization*: seluruh *loss* digabungkan secara *end-to-end*, memungkinkan model mempelajari hubungan spasial antar-tugas secara simultan.

Pendekatan ini menunjukkan peningkatan akurasi sebesar 2–3% dibanding U-Net konvensional dan menghasilkan kontur batas yang lebih presisi. Dalam konteks penelitian ini, konsep *inter-task relevance* diadopsi untuk menghubungkan cabang segmentasi dengan regresi luasan luka, sehingga nilai area yang diprediksi lebih akurat dan selaras dengan morfologi keloid yang sebenarnya.

3. MTL untuk Analisis Warna (Colorimetry) berdasarkan *Accuracy and Precision of Smartphone Colorimetry: A Comparative Analysis in RGB, HSV, and CIELAB Color Spaces*

Sirisathitkul et al. (2025) mengembangkan metode analisis warna berbasis *digital colorimetry* menggunakan citra yang diambil melalui kamera smartphone. Studi ini membandingkan tiga ruang warna RGB, HSV, dan CIELAB untuk menilai akurasi serta presisi pengukuran warna dibandingkan standar referensi Pantone.

Metode yang digunakan mencakup:

- Pengambilan Citra dan Kalibrasi: setiap gambar dikalibrasi menggunakan kartu warna standar untuk mengoreksi perbedaan pencahayaan.
- Ekstraksi Warna Dominan: nilai warna diekstraksi dengan metode *k-means clustering*, menghasilkan tiga warna dominan yang mewakili karakteristik utama permukaan objek.
- Evaluasi Presisi: dilakukan uji komparatif antara nilai warna hasil pengukuran dengan standar Pantone menggunakan metrik ΔE (CIELAB) dan MSE (RGB).

Dalam penelitian ini, analisis warna dilakukan pada ruang warna RGB, karena penelitian Sirisathitkul et al. (2025) menunjukkan bahwa RGB memiliki korelasi tinggi dengan persepsi warna alami kulit. Setiap area luka hasil segmentasi diekstraksi menggunakan metode K-Means clustering ($k=3$) untuk mendapatkan tiga warna dominan. Nilai rata-rata RGB dari tiap cluster kemudian digunakan sebagai representasi warna jaringan, yang selanjutnya dibandingkan dengan nilai referensi klinis untuk menilai kondisi keloid (inflamasi, maturasi, atau hiperpigmentasi).

Hasil penelitian menunjukkan bahwa ruang warna RGB dan CIELAB memiliki korelasi tinggi dengan nilai referensi standar, menjadikannya ideal untuk analisis kuantitatif berbasis citra. Prinsip ini diadaptasi dalam penelitian ini untuk cabang analisis warna (colorimetry), yang memanfaatkan rasio RGB dari

area luka hasil segmentasi guna menilai perubahan fisiologis keloid seperti tingkat inflamasi, maturasi, dan hiperpigmentasi.

2.1.5 Long Short-Term Memory (LSTM) dan Analisis Citra Time-Series

Long Short-Term Memory (LSTM) merupakan arsitektur turunan dari *Recurrent Neural Network* (RNN) yang dikembangkan oleh Hochreiter & Schmidhuber (1997) untuk mengatasi permasalahan *vanishing gradient* dan *long-term dependency*. LSTM memiliki struktur khusus berupa *cell state* dan tiga gate (*input*, *forget*, dan *output*) yang berfungsi untuk mengatur aliran informasi dalam urutan data.

1. Mekanisme LSTM

Secara umum, alur data dalam LSTM dapat dijelaskan sebagai berikut:

- *Forget Gate* menentukan informasi mana dari state sebelumnya yang akan dibuang.
- *Input Gate* menentukan informasi baru apa yang akan disimpan ke dalam cell state.
- *Output Gate* menentukan bagian dari cell state yang akan digunakan sebagai output pada langkah waktu berikutnya.

2. Formula Matematis LSTM

Persamaan berikut menjelaskan mekanisme kerja *Long Short-Term Memory* (LSTM) dalam memproses urutan data secara temporal. Setiap simbol memiliki fungsi spesifik untuk mengatur bagaimana informasi lama disimpan, diperbarui, atau dibuang pada setiap langkah waktu t :

1. Forget Gate (f_t)

Mengontrol seberapa banyak informasi dari *cell state* sebelumnya (C_{t-1}) akan dipertahankan atau dilupakan. Nilai keluaran f_t berada di antara 0–1 (melalui fungsi sigmoid), di mana 1 berarti informasi dipertahankan sepenuhnya dan 0 berarti dihapus sepenuhnya.

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad \dots (7)$$

2. Input Gate (i_t)

Menentukan seberapa besar informasi baru (C_t) akan ditambahkan ke *cell state*.

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad \dots (8)$$

3. Candidate Cell State ($\tilde{C}_t$)

Merupakan kandidat informasi baru yang akan dimasukkan ke *cell state*, dihitung dengan fungsi aktivasi *tanh* agar nilainya berada dalam rentang $[-1,1]$.

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad \dots (9)$$

4. Update Cell State (C_t)

Cell state diperbarui dengan menggabungkan informasi lama yang dipertahankan ($f_t \times C_{t-1}$) dan informasi baru yang masuk ($i_t \times \tilde{C}_t$):

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad \dots (10)$$

5. Output Gate (o_t)

Menentukan bagian mana dari cell state yang akan dikeluarkan sebagai hidden state baru.

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad \dots (11)$$

6. Hidden State Baru (h_t)

Merupakan keluaran akhir dari LSTM pada langkah waktu t , hasil kombinasi antara *cell state* terkini dan *output gate*:

$$h_t = o_t \times \tanh(C_t) \quad \dots (12)$$

Dengan mekanisme ini, LSTM mampu mengingat informasi penting dari langkah waktu sebelumnya dan mengabaikan informasi yang tidak relevan, sehingga sangat efektif untuk data berurutan seperti *time-series image* pada penelitian ini.


3. Fungsi aktivasi

Fungsi aktivasi utama yang digunakan dalam LSTM adalah:

- σ : fungsi sigmoid, membatasi nilai antara 0 - 1, digunakan untuk mengontrol seberapa banyak informasi diteruskan.
- $\tanh$: fungsi hiperbolik, menjaga keseimbangan nilai positif dan negatif agar *cell state* tetap stabil selama pelatihan.

4. Penerapan dalam Penelitian

Dalam penelitian ini, LSTM digunakan setelah fitur spasial diekstraksi oleh CNN. Dengan demikian, CNN bertindak sebagai *feature extractor*, sedangkan LSTM menangkap *dynamics temporal* dari perubahan keloid dalam beberapa interval waktu. Pendekatan CNN+LSTM ini memungkinkan model memahami evolusi morfologi dan warna keloid secara longitudinal. Penelitian terkini menunjukkan bahwa integrasi spasial-temporal ini meningkatkan akurasi prediksi perkembangan lesi dan memperbaiki interpretasi klinis pada evaluasi luka kronis, tumor, maupun terapi keloid (Wang et al., 2023).



Gambar 2.3 Skema arsitektur LSTM (Sumber Hochreiter & Schmidhuber, 1997; Goodfellow et al., 2016).

Arsitektur *Long Short-Term Memory* (LSTM) digunakan untuk memproses data sekuensial dengan mempertahankan informasi jangka panjang melalui *forget*, *input*, dan *output gate* (Hochreiter & Schmidhuber, 1997). Pada penelitian ini, LSTM relevan karena citra keloid dikumpulkan secara *longitudinal* (time-series) dari bulan pertama hingga ketiga. Dengan ditempatkan setelah backbone CNN, LSTM mampu menangkap pola temporal perubahan bentuk, ukuran, dan warna keloid, sehingga hasil segmentasi, pengukuran luas, dan analisis warna menjadi lebih stabil dan akurat dibandingkan pendekatan citra tunggal.

2.1.6 Segment Anything Model (SAM) dan Vision Transformer (ViT)

Segmentation merupakan salah satu tugas penting dalam *computer vision*, di mana model diharapkan mampu membagi citra menjadi area-area yang bermakna berdasarkan objek atau struktur yang ingin dianalisis. Segment Anything Model (SAM) adalah sebuah *foundation model* untuk segmentasi citra yang dirancang agar mampu memprediksi *mask* segmentasi dari berbagai macam objek hanya dengan sedikit isyarat (*prompt*) dari pengguna, seperti titik atau kotak. SAM dilatih menggunakan dataset berskala besar yang mencakup lebih dari satu miliar *mask* pada 11 juta citra, sehingga menunjukkan kemampuan generalisasi yang kuat terhadap berbagai domain segmentasi gambar tanpa memerlukan pelatihan ulang (*zero-shot transfer*). Dalam arsitekturnya, SAM menggunakan *Image Encoder* berbasis Vision Transformer (ViT) untuk menghasilkan representasi fitur citra, *Prompt Encoder* untuk mengodekan informasi prompt, serta *Mask Decoder* untuk menghasilkan prediksi segmentasi akhir dari gabungan representasi tersebut (Kirillov et al., 2023).

Vision Transformer (ViT) merupakan arsitektur model berbasis *transformer* yang awalnya diperkenalkan untuk tugas klasifikasi citra, namun kemudian banyak diadopsi pada berbagai tugas visi komputer lanjutan, termasuk segmentasi citra. ViT memproses citra dengan membaginya menjadi *patch* berukuran tetap yang diproyeksikan ke dalam ruang embedding dan diproses oleh *transformer encoder* menggunakan mekanisme *self-attention*. Pendekatan ini memungkinkan model untuk menangkap hubungan global antar *patch* citra, berbeda dengan Convolutional Neural Network (CNN) yang lebih menekankan pada ekstraksi fitur lokal. ViT telah terbukti memiliki performa yang

kompetitif dan bahkan unggul dibandingkan model berbasis CNN ketika dilatih pada dataset berskala besar (Dosovitskiy et al., 2021).

Dalam konteks penelitian ini, Segment Anything Model (SAM) digunakan pada tahap pra-pemrosesan data untuk menghasilkan *mask* luka keloid yang selanjutnya digunakan sebagai referensi dalam pengembangan dataset. Pendekatan ini bertujuan untuk meningkatkan konsistensi dan efisiensi proses anotasi *mask* tanpa perlu melatih model segmentasi khusus dari awal untuk setiap citra luka. Integrasi SAM dengan pipeline penelitian dilakukan secara terpisah dari proses pelatihan model CNN–LSTM–Multi-Task Learning yang dikembangkan untuk tugas segmentasi, estimasi luasan, dan analisis warna luka secara temporal. Dengan demikian, SAM berfungsi sebagai alat bantu generatif, sedangkan model CNN–LSTM difokuskan pada pembelajaran terarah terhadap tugas-tugas klinis yang menjadi fokus utama penelitian ini (Kirillov et al., 2023; Dosovitskiy et al., 2021).

2.2 Systematic Literature Review (SLR)

2.2.1 Metode SLR

Kajian literatur sistematis ini disusun mengikuti pedoman PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) untuk memastikan transparansi dan reproduktibilitas. Pertanyaan penelitian dirumuskan dengan kerangka PICO (*Population, Intervention, Comparison, Outcome*) sebagai berikut:

- Population: penelitian yang mengimplementasikan *Multi-Task Learning (MTL)* berbasis *deep learning* pada citra medis dua dimensi (CT, MRI, X-ray, dermoscopy, ultrasound), serta studi yang menggunakan analisis citra digital berbasis RGB/HDR untuk *colorimetry* atau evaluasi visual jaringan medis dalam periode 2020-2025.
- Intervention: penerapan arsitektur *deep learning* seperti CNN, U-Net, ResNet, EfficientNet, dan CNN-Transformer hybrid yang menggabungkan lebih dari satu tugas pembelajaran, seperti segmentasi klasifikasi, segmentasi pengukuran, atau segmentasi analisis warna.
- Comparison: perbandingan performa model MTL terhadap *single-task learning* tradisional, serta perbandingan efektivitas metode analisis citra berbasis *deep*

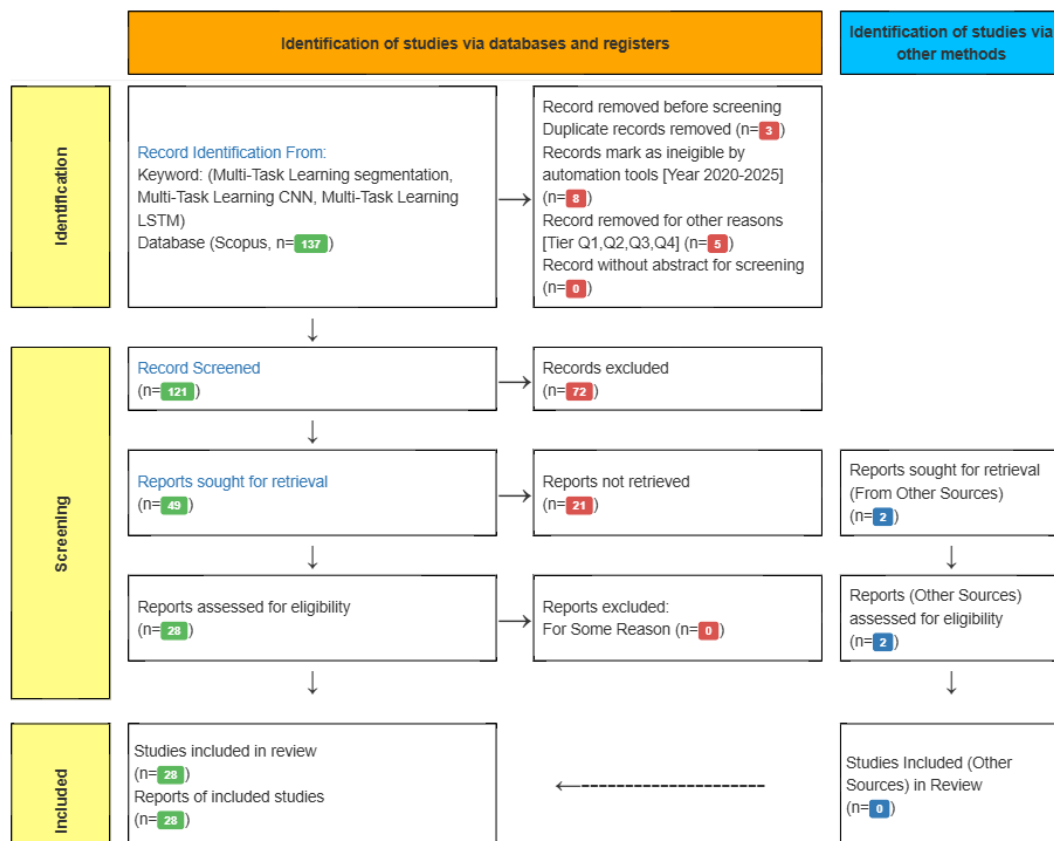
learning dengan pendekatan kemometri konvensional (PCA, PLS) atau representasi ruang warna (RGB vs HDR).

- Outcome: evaluasi performa model menggunakan metrik kuantitatif seperti Dice Score, IoU, akurasi, sensitivitas, spesifisitas, F1-score, MAE, RMSE, serta parameter *colorimetry* seperti rasio RGB, nilai CIELAB, dan Limit of Detection (LOD).

Proses pencarian literatur dilakukan secara sistematis pada lima basis data ilmiah utama, yaitu Scopus, PubMed, IEEE Xplore, ScienceDirect, dan SpringerLink. Proses pencarian dibagi menjadi dua kelompok utama berdasarkan fokus penelitian, yaitu:

1. Pencarian Literatur Topik Multi-Task Learning (MTL)

Difokuskan pada studi yang menerapkan Multi-Task Learning (MTL) berbasis *deep learning* untuk analisis citra medis dua dimensi. Dari hasil pencarian literatur di database *Scopus* (n=137) dan sumber lain (n=2), dilakukan penyaringan berdasarkan duplikasi, rentang tahun (2020–2025), serta kualitas jurnal. Sebanyak 121 artikel diseleksi berdasarkan judul dan abstrak, menghasilkan 49 artikel potensial, dan 28 studi akhir memenuhi kriteria inklusi untuk ditinjau. Proses seleksi ditunjukkan pada Gambar 2.4 dalam *Diagram PRISMA 2020*.



Gambar 2.4 Diagram alur seleksi literatur SLR pada topik multi-task learning.

2. Pencarian Literatur Topik Keloid Scars, Area Measurement, dan Colorimetry

Difokuskan pada studi yang membahas analisis citra digital, pengukuran area jaringan, dan evaluasi warna (*colorimetry*) pada objek medis, khususnya keloid dan jaringan kulit. Pencarian dibatasi pada periode publikasi 2020–2025, bahasa Inggris, dan artikel ilmiah terindeks Scopus (Q1–Q4) atau jurnal bereputasi internasional lainnya. Proses identifikasi awal menemukan 607 rekam literatur dari basis data Scopus. Setelah eliminasi berdasarkan tahun publikasi dan kelengkapan abstrak, 289 artikel dikeluarkan, menyisakan 318 studi untuk tahap *screening*. Dari hasil penyaringan, 168 artikel dievaluasi lebih lanjut pada tahap *full-text review*, dan setelah eksklusi berdasarkan relevansi konten, 79 studi akhir dinyatakan memenuhi kriteria inklusi dan dimasukkan dalam analisis. Alur proses seleksi ini divisualisasikan dalam Gambar 2.5 dalam bentuk Diagram PRISMA 2020.



Gambar 2.5 Diagram alur seleksi literatur SLR pada topik Keloid Scars treatment, Area Measurement, and Colorimetry

2.2.2 Hasil SLR

Kajian literatur sistematis yang dilakukan dalam penelitian ini mengungkapkan dua tren utama dalam pengembangan analisis citra medis berbasis pembelajaran mesin, yaitu penerapan Multi-Task Learning (MTL) pada citra medis dua dimensi, serta analisis warna berbasis citra digital (colorimetry).

Pada topik Multi-Task Learning (MTL) pada citra medis 2D, sebagian besar penelitian memanfaatkan kerangka MTL untuk mengintegrasikan segmentasi dan klasifikasi dalam satu model *end-to-end*. Pendekatan ini terbukti meningkatkan efisiensi serta akurasi diagnosis karena memungkinkan *feature sharing* antar-tugas, sehingga model dapat belajar konteks spasial dan semantik secara bersamaan. Sebagai contoh, Al-Masni et al. (2024) mengembangkan model *unified MTL* dengan mekanisme *joint reverse*

optimization untuk tugas simultan segmentasi dan diagnosis lesi kulit. Model ini menggabungkan fitur dari jalur *encoder-decoder* berbasis U-Net dengan *fully connected layers* untuk klasifikasi, serta memperkenalkan *reverse learning connection* antara submodul klasifikasi dan segmentasi. Pendekatan ini mampu menyeimbangkan dominasi antar-tugas dan meningkatkan hasil kedua tugas secara signifikan mencapai Dice Similarity Coefficient (DSC) sebesar 89,48% untuk segmentasi dan F1-score sebesar 82,07% untuk klasifikasi pada dataset ISIC 2016 dan PH2. Performa model terbukti meningkat signifikan ketika U-Net dikombinasikan dengan mekanisme tambahan seperti attention mechanism, residual blocks, maupun backbone pretrained seperti ResNet50 dan EfficientNet (Chen et al., 2020). Tren penelitian terkini menunjukkan munculnya arsitektur hybrid CNN + Transformer, yang menawarkan kemampuan lebih baik dalam menangkap konteks global sekaligus detail spasial. Selain itu, MTL meningkatkan efisiensi pelatihan melalui *parameter sharing*, yang memungkinkan pemanfaatan fitur bersama dan mempercepat konvergensi. Pendekatan ini juga terbukti mengurangi overfitting pada dataset medis berukuran kecil, karena pembelajaran multi-tugas membantu menyeimbangkan gradien dan memperkuat generalisasi model (Alenezi et al., 2023).

Sementara itu, pada ranah analisis warna berbasis citra digital (colorimetry), literatur menunjukkan bahwa representasi warna dalam ruang RGB, HSV, dan CIELAB mampu merefleksikan kondisi biologis penting seperti kandungan melanin, hemoglobin, serta tingkat inflamasi pada jaringan (Berasarte et al., 2025). Pendekatan paling banyak digunakan adalah RGB image analysis berbasis kamera digital atau smartphone karena sifatnya yang murah, portabel, dan mudah diterapkan di lapangan. Untuk ekstraksi warna dominan, metode K-Means Clustering dan Mean Shift Clustering merupakan pilihan populer. Aplikasi medisnya meliputi evaluasi luka kronis, pemantauan perkembangan terapi keloid, hingga digital histopathology. Lebih jauh lagi, tren terbaru mengarah pada integrasi colorimetry dengan deep learning, terutama CNN, U-Net, dan attention-based models, yang mampu meningkatkan akurasi analisis secara signifikan dibandingkan metode tradisional berbasis kemometri seperti PCA atau PLS (Abdolahnejad et al., 2024).

Kedua pendekatan ini memiliki potensi sinergis: MTL menyediakan kerangka otomatisasi multi-fungsi, sedangkan colorimetry memberikan indikator fisiologis

kuantitatif. Kombinasi keduanya memungkinkan sistem analisis citra medis yang lebih *holistic* tidak hanya memetakan bentuk dan ukuran, tetapi juga kondisi biologis jaringan secara visual. Tren penelitian terbaru (2020-2025) menunjukkan meningkatnya minat pada integrasi pembelajaran multimodal dan temporal seperti CNN-LSTM dan *Vision Transformer* (ViT), namun masih terbatas pada citra CT dan MRI, belum pada citra RGB klinis.

Secara keseluruhan, hasil SLR ini menegaskan bahwa baik MTL maupun colorimetry digital telah menjadi pendekatan penting dalam medical image analysis. Namun, belum ada penelitian yang mengintegrasikan keduanya dalam satu kerangka kerja *end-to-end* yang juga mempertimbangkan aspek temporal. Oleh karena itu, penelitian ini mengusulkan pengembangan model CNN-LSTM berbasis *Multi-Task Learning* yang mampu melakukan segmentasi, pengukuran luasan, dan analisis warna (*colorimetry*) secara bersamaan pada citra RGB *time-series* jaringan keloid.

2.2.3 Gap Analysis

Berdasarkan hasil kajian literatur sistematis terhadap penelitian terkini (2020 s.d 2025), diperoleh beberapa kesenjangan penelitian yang menjadi dasar pengembangan tesis ini, antara lain:

1. Ruang lingkup implementasi Multi-Task Learning (MTL) masih terbatas. Sebagian besar penelitian MTL pada citra medis hanya mengintegrasikan tugas segmentasi dan klasifikasi dalam satu arsitektur *end-to-end*. Belum ditemukan model yang secara bersamaan menggabungkan segmentasi, pengukuran luasan, dan analisis warna dalam satu kerangka terpadu.
2. Analisis warna belum terintegrasi dengan model deep learning. Pendekatan digital colorimetry pada bidang medis umumnya masih menggunakan metode statistik atau kemometri konvensional. Padahal, informasi warna dalam ruang RGB dan CIELAB memiliki potensi penting untuk merepresentasikan kondisi biologis jaringan, seperti inflamasi, vaskularisasi, dan hiperpigmentasi.
3. Fokus penelitian segmentasi medis masih dominan pada citra radiologi statis. Sebagian besar model segmentasi dikembangkan untuk citra CT atau MRI yang

bersifat *grayscale* dan tidak mencerminkan variasi warna serta tekstur jaringan kulit. Analisis berbasis citra RGB klinis yang lebih representatif terhadap kondisi permukaan kulit masih sangat terbatas.

4. Minimnya pendekatan pemodelan temporal pada citra medis. Hampir seluruh penelitian yang ada bersifat *single-frame*, sehingga belum mampu menangkap perubahan morfologi dan warna jaringan secara longitudinal. Aspek temporal dalam pemantauan luka atau perkembangan keloid belum banyak dieksplorasi melalui integrasi CNN dan model sekuensial seperti LSTM.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut melalui pengembangan model CNN-LSTM berbasis *Multi-Task Learning* (MTL) yang mampu melakukan segmentasi, pengukuran luasan, dan analisis colorimetry secara simultan pada citra RGB *time-series* keloid. Pendekatan ini diharapkan dapat menghasilkan sistem penilaian keloid yang lebih objektif, efisien, serta dapat diterapkan dalam konteks klinis untuk pemantauan luka secara longitudinal.

2.2.4 Kesimpulan SLR

Secara keseluruhan, hasil kajian literatur menunjukkan bahwa:

1. Pendekatan *Multi-Task Learning* (MTL) berbasis deep learning menunjukkan kinerja unggul dibandingkan pendekatan *single-task*. MTL memungkinkan pembelajaran bersama beberapa tugas seperti segmentasi dan klasifikasi dalam satu arsitektur *end-to-end*, sehingga meningkatkan efisiensi pelatihan dan generalisasi model pada dataset medis yang terbatas. Berbagai penelitian menunjukkan bahwa integrasi tugas-tugas yang saling berkaitan dapat meningkatkan stabilitas pembelajaran serta menekan risiko *overfitting*, dengan capaian performa segmentasi mencapai *Dice Score* di atas 0,85 dan akurasi klasifikasi melebihi 90%.
2. Analisis warna (*digital colorimetry*) memiliki potensi besar sebagai metode penilaian jaringan non-invasif. Representasi warna dalam ruang RGB, HSV, dan CIELAB terbukti mampu merefleksikan perubahan biologis pada jaringan, seperti inflamasi, vaskularisasi, dan pigmentasi. Pendekatan ini bersifat murah, portabel,

serta dapat digunakan untuk pemantauan kondisi luka dan keloid secara kuantitatif. Namun, sebagian besar studi masih menggunakan pendekatan kolorimetri konvensional dan belum mengintegrasikannya ke dalam model deep learning berbasis citra RGB secara otomatis.

3. Penerapan teknologi analisis citra medis secara klinis masih menghadapi sejumlah tantangan. Tantangan utama meliputi keterbatasan dataset publik berskala besar dengan anotasi warna dan area yang terstandar, kebutuhan validasi lintas populasi, serta integrasi sistem analisis citra secara *real-time* di lingkungan klinis. Sebagian besar penelitian masih bersifat eksperimental dan belum diterapkan secara luas untuk evaluasi longitudinal kondisi jaringan.

Berdasarkan temuan tersebut, penelitian ini menempati posisi strategis dalam mengisi kesenjangan dengan mengembangkan model CNN-LSTM berbasis *Multi-Task Learning* yang mampu melakukan segmentasi, pengukuran luasan, dan analisis warna secara simultan pada citra RGB *time-series* keloid. Pendekatan ini diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan sistem penilaian keloid yang lebih objektif, efisien, dan aplikatif dalam praktik klinis.

Selanjutnya, berdasarkan hasil kajian literatur sistematis yang telah dilakukan, dapat disimpulkan bahwa arah penelitian terkini dalam analisis citra medis menunjukkan dua fokus utama, yaitu pengembangan arsitektur *Multi-Task Learning (MTL)* untuk meningkatkan efisiensi dan akurasi model, serta pemanfaatan *digital colorimetry* sebagai pendekatan kuantitatif dalam menilai karakteristik biologis jaringan. Meskipun kedua pendekatan tersebut telah terbukti efektif secara terpisah, integrasi keduanya dalam satu kerangka *end-to-end* yang juga mempertimbangkan aspek temporal masih sangat terbatas.

Oleh karena itu, untuk memperkuat temuan hasil SLR dan mendukung landasan konseptual penelitian ini, bagian berikutnya menyajikan penelitian-penelitian terkait yang secara empiris mewakili tren utama tersebut. Kajian ini berfokus pada studi yang mengimplementasikan *MTL* pada segmentasi dan klasifikasi citra medis dua dimensi, serta penelitian yang menerapkan *colorimetric analysis* pada citra luka dan jaringan kulit. Dengan demikian, bagian *Penelitian Terkait* berfungsi untuk menjembatani hasil sintesis

teoretis dari SLR dengan dasar empiris yang akan menjadi pijakan dalam perancangan model CNN-LSTM berbasis MTL pada penelitian ini.

2.3 PENELITIAN TERKAIT

2.3.1 Segmentasi dan Klasifikasi Citra Medis berbasis *Deep Learning*

Perkembangan teknologi *deep learning* telah menghasilkan kemajuan signifikan dalam segmentasi citra medis, terutama untuk mendeteksi area jaringan abnormal seperti lesi kulit, luka kronis, atau tumor. Pendekatan *Convolutional Neural Network* (CNN) menjadi dasar dari berbagai arsitektur canggih seperti U-Net, EfficientNet, dan ResNet yang terbukti efektif dalam menangkap fitur spasial pada citra medis.

Studi oleh Abdolahnejad et al. (2024) dalam *A Prototype Machine Learning Pipeline for Assessing and Tracking Keloid Scars* mengembangkan sistem berbasis CNN untuk mendeteksi, mengukur, dan menganalisis warna jaringan keloid dari citra RGB 2D. Model ini memanfaatkan *fiducial marker* untuk kalibrasi ukuran dan menerapkan *K-Means clustering* untuk analisis warna. Pipeline tersebut menunjukkan akurasi klasifikasi 98% dengan kemampuan memantau perubahan ukuran dan warna keloid secara longitudinal.

Sementara itu, Al-Masni et al. (2024) dalam *A Unified Multi-Task Learning Model with Joint Reverse Optimization for Simultaneous Skin Lesion Segmentation and Diagnosis* memperkenalkan pendekatan *Multi-Task Learning (MTL)* yang secara simultan melakukan segmentasi dan klasifikasi lesi kulit. Dengan menerapkan strategi *joint reverse learning*, model ini mencapai nilai *Dice Similarity Coefficient* sebesar 89.48% pada dataset ISIC 2016 dan meningkatkan *F1-score* klasifikasi hingga 85.50%. Penelitian ini menunjukkan keunggulan arsitektur MTL dalam meningkatkan akurasi kedua tugas melalui pembelajaran bersama.

Selain itu, He et al. (2021) melalui *HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images* memperkenalkan arsitektur *hierarchically fused U-Net (HF-UNet)* yang menggabungkan dua tugas berbeda, yaitu segmentasi utama dan segmentasi batas (*boundary delineation*) sebagai tugas tambahan. Pendekatan ini terbukti mampu memperbaiki kejelasan batas

organ pada citra dengan kontras rendah dan meningkatkan konsistensi antar-tugas dalam kerangka MTL.

Dalam konteks longitudinal, Li et al. (2021) mengembangkan *Segis-Net*, sebuah framework *single-step deep learning* untuk *simultaneous segmentation and registration* pada data MRI serial. Model ini memanfaatkan informasi temporal untuk mempertahankan konsistensi spasio-temporal antar waktu, sehingga sangat relevan untuk studi luka yang diamati secara berkala seperti keloid.

Tinjauan komprehensif oleh Cassidy et al. (2025) dalam *Deep Learning in Chronic Wound Segmentation: A Comprehensive Review and Meta-analysis* juga menyoroti bahwa CNN, terutama U-Net dan turunannya, telah menjadi standar dalam segmentasi luka kronis, meskipun tantangan seperti keterbatasan dataset dan variasi warna jaringan masih menjadi hambatan utama.

Pendekatan-pendekatan ini menunjukkan bahwa model CNN dan MTL berpotensi tinggi untuk diadaptasi pada citra keloid, yang memiliki kompleksitas bentuk dan variasi warna serupa dengan lesi kulit lainnya.

2.3.2 Colorimetric Analysis pada Citra Luka dan Jaringan Kulit

Analisis warna (*colorimetry*) merupakan aspek penting dalam evaluasi jaringan kulit dan luka, karena perubahan warna sering kali berkorelasi dengan proses biologis seperti inflamasi, hiperpigmentasi, dan fase penyembuhan jaringan. Warna menjadi salah satu indikator klinis yang mudah diamati namun sulit diukur secara objektif tanpa bantuan sistem digital.

Penelitian oleh Abdollahnejad et al. (2024) secara eksplisit mengintegrasikan *colorimetry* ke dalam *pipeline* deteksi keloid. Mereka menggunakan metode K-Means clustering pada citra RGB untuk menilai heterogenitas pigmen pada jaringan keloid. Hasil penelitian menunjukkan bahwa variasi nilai RGB berhubungan dengan perubahan warna kulit pasien, yang dapat dipantau secara longitudinal untuk menilai progres terapi.

Sementara itu, Tang et al. (2022) dalam penelitiannya "*Diagnosis of Esophageal Lesions by Multi-Classification and Segmentation Using an Improved Multi-Task Deep*

Learning Model” menggabungkan analisis warna dan tekstur sebagai fitur tambahan untuk meningkatkan akurasi segmentasi dan klasifikasi lesi esofagus. Mereka memanfaatkan ResNet50 sebagai backbone CNN dengan *hard parameter sharing* untuk berbagi representasi spasial yang mencakup informasi intensitas warna dan bentuk jaringan. Walaupun fokus utama penelitian ini bukan pada colorimetry secara eksplisit, penggunaan fitur warna terbukti berkontribusi terhadap peningkatan performa model dalam membedakan jaringan sehat dan patologis. Pendekatan ini relevan bagi penelitian ini, karena menunjukkan bahwa fitur warna dapat memperkuat pembelajaran lintas-tugas (cross-task learning) antara segmentasi dan analisis warna keloid.

Selain itu, Sirisathitkul et al. (2025) dalam “*Accuracy and Precision of Smartphone Colorimetry: A Comparative Analysis in RGB, HSV, and CIELAB Color Spaces*” membandingkan akurasi pengukuran warna menggunakan tiga ruang warna utama (RGB, HSV, dan CIELAB). Studi ini menemukan bahwa ruang warna CIELAB memberikan presisi tinggi terhadap warna alami, sementara HSV lebih menyerupai persepsi visual manusia terhadap intensitas dan saturasi. Temuan ini sangat relevan untuk penelitian keloid, karena pemilihan ruang warna yang tepat dapat meningkatkan reliabilitas analisis warna jaringan secara kuantitatif.

Di sisi lain, Cassidy et al. (2025) dalam tinjauan meta-analisisnya mencatat bahwa fitur warna dalam ruang RGB dan HSV sering dimanfaatkan dalam segmentasi luka untuk membedakan jaringan nekrotik, fibrin, dan granulasi. Warna jaringan menjadi indikator penting kondisi luka, sehingga penggabungan fitur warna dan tekstur terbukti meningkatkan akurasi segmentasi.

Meskipun berbagai studi telah meneliti fitur warna dalam konteks luka dan jaringan kulit, sebagian besar studi analisis warna pada luka masih terpisah dari proses segmentasi dan pengukuran area. Penelitian ini berupaya mengisi kesenjangan tersebut dengan mengembangkan sistem *Multi-Task Learning* berbasis CNN-LSTM yang secara simultan melakukan segmentasi, pengukuran luasan, dan analisis warna pada citra RGB *time-series* keloid untuk mendukung pemantauan penyembuhan luka secara objektif dan berkelanjutan.

2.3.3 Tabel Perbandingan Penelitian Terkait

Tabel 2.3 merangkum perbandingan penelitian terdahulu terkait segmentasi dan colorimetry pada citra luka atau lesi kulit, mencakup algoritma yang digunakan, tujuan penelitian, serta aspek segmentasi, luasan, dan analisis warna. Sebagian besar studi masih berfokus pada tugas tunggal (*single-task*) seperti segmentasi atau analisis warna. Hanya beberapa, seperti He et al. (2021) dan Li et al. (2021), yang menerapkan Multi-Task Learning (MTL) untuk mengintegrasikan segmentasi dan regresi.

Adapun penelitian oleh Lailatul Hayani (2025) berbeda dari studi sebelumnya karena menjadi satu-satunya yang menggabungkan segmentasi, pengukuran luasan, dan analisis warna secara simultan melalui arsitektur CNN-LSTM berbasis MTL end-to-end, sehingga memberikan kontribusi baru dalam analisis citra keloid spatio-temporal.

Tabel 2.1 Tabel Perbandingan Penelitian Terkait

Judul Penelitian	Peneliti	Algoritma	Fokus	Tipe Arsitektur	Segmentasi	Luasan/ Regresi	Colorimetry
Deep Learning in Chronic Wound Segmentation: A Comprehensive Review and Meta-analysis	Cassidy et al. (2025)	U-Net, ResNet, FCN (review)	Tinjauan segmentasi luka kronis dengan deep learning	Single-task	Ya	Tidak	Tidak
A Prototype Machine Learning Pipeline for Assessing and Tracking Keloid Scars	Abdolahnejad et al. (2024)	CNN + K-Means clustering	Deteksi, pengukuran, dan analisis warna keloid RGB	Single-task (pipeline modular)	Ya	Ya	Ya
Diagnosis of Esophageal Lesions by Multi-Classification and	Tang et al. (2022)	Multi-Task CNN (ResNet50 Backbone)	Segmentasi dan klasifikasi lesi esofagus secara simultan	Multi-task (hard parameter sharing)	Ya	Tidak	Tidak

Segmentation Using an Improved Multi-Task Deep Learning Model							
HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images	He et al. (2021)	Hierarchical Multi-Task U-Net (HF-UNet)	Segmentasi prostat dan delineasi batas organ	Multi-task	Ya	Ya	Tidak
Longitudinal Diffusion MRI Analysis Using Segis-Net: A Single-Step Deep-Learning Framework for Simultaneous	Li et al. (2021)	Segis-Net (CNN + Registration + Temporal Modeling)	Segmentasi MRI serial dengan konsistensi longitudinal	Multi-task (spatio-temporal)	Ya	Ya	Tidak

Segmentation and Registration							
Accuracy and Precision of Smartphone Colorimetry: A Comparative Analysis in RGB, HSV, and CIELAB Color Spaces	Sirisathitkul et al. (2025)	Colorimetric Comparison (RGB, HSV, CIELAB)	Analisis akurasi warna digital antar ruang warna	Single-task	Tidak	Tidak	Ya
Segmentasi, Pengukuran Luasan, dan Colorimetry pada Scar Keloid	Lailatul Hayani (2025)	CNN + LSTM (MTL end-to-end)	CNN + LSTM (MTL end-to-end)	Multi-task (spatio-temporal)	Ya	Ya	Ya

BAB 3

METODOLOGI PENELITIAN

3.1 METODOLOGI PENELITIAN

3.1.1 Pendekatan Penelitian

Penelitian ini mengadopsi pendekatan kuantitatif eksperimental berbasis *deep learning* dengan desain komputasional. Pemilihan pendekatan kuantitatif dilatarbelakangi oleh kebutuhan untuk mengukur performa model secara objektif melalui metrik numerik, seperti akurasi segmentasi menggunakan Dice Score, error regresi luas (MAE, RMSE), maupun error prediksi warna (MSE).

Pendekatan eksperimental dipilih karena penelitian ini berfokus pada pengembangan dan pengujian model Multi-Task Learning (MTL) berbasis Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM). CNN digunakan untuk mengekstraksi fitur spasial dari citra keloid, sedangkan LSTM dipakai untuk memodelkan urutan citra secara temporal. Dengan memanfaatkan MTL, penelitian ini mampu mengintegrasikan tiga tugas utama segmentasi, pengukuran luasan, dan analisis warna dalam satu arsitektur end-to-end.

Keunggulan pendekatan ini dibandingkan pipeline konvensional adalah:

1. Efisiensi komputasi hanya melatih satu model untuk tiga tugas sekaligus.
2. Transfer pengetahuan antar-tugas hasil segmentasi dapat memperkuat akurasi pengukuran luas dan analisis warna.
3. Konsistensi hasil model tidak terpecah menjadi modul terpisah sehingga mengurangi propagasi error.

Hal ini sesuai dengan temuan dalam *Systematic Review MTL* yang menekankan bahwa model multi-task memberikan keunggulan signifikan pada domain citra medis, khususnya dalam hal efisiensi, generalisasi, dan akurasi. Sementara itu, tinjauan

sistematis tentang digital image-based detection technologies menunjukkan bahwa CNN, U-Net, dan ResNet merupakan arsitektur yang paling dominan digunakan dalam segmentasi dan klasifikasi citra medis, sehingga relevan untuk digunakan dalam penelitian ini.

3.1.2 Model Multi-Task Learning yang Digunakan

Model yang dikembangkan merupakan kombinasi CNN–LSTM yang diintegrasikan dalam kerangka MTL dengan tiga cabang output. Arsitektur model dapat dijelaskan sebagai berikut:

1. Encoder CNN bertugas mengekstraksi fitur spasial dari citra keloid. ResNet50 dipilih karena berdasarkan literatur memiliki kemampuan representasi yang kuat dan stabil pada data medis, serta dapat memanfaatkan bobot *pretrained* dari dataset ImageNet untuk mempercepat proses *convergence*.
2. LSTM untuk pemodelan temporal citra keloid dikumpulkan dalam urutan (time-series) 3–5 frame per pasien. LSTM digunakan untuk mempelajari hubungan temporal antar-citra, sehingga model dapat mengenali pola perkembangan keloid dari waktu ke waktu.
3. Cabang Output Multi-Task

Representasi fitur hasil CNN–LSTM dibagi ke dalam tiga cabang berikut:

- Segmentasi area keloid: menggunakan *decoder* berbasis U-Net untuk menghasilkan *mask* biner dari area luka. U-Net dipilih karena terbukti efektif dalam penelitian segmentasi medis (Ronneberger et al., 2015).
- Regresi luas luka: *fully connected layer* yang menghitung luasan luka dalam cm² berdasarkan hasil segmentasi dan referensi fiducial marker.
- Analisis warna (colorimetry): *dense layer* yang memprediksi distribusi warna dominan dalam rasio Lab.

4. Loss Function Gabungan Terdiri atas Dice/IoU Loss (segmentasi), MAE & RMSE (luas luka), serta MSE (warna). Loss dari ketiga cabang digabungkan menggunakan pembobotan, dengan uncertainty weighting (Kendall et al., 2018) sebagai strategi utama untuk menyeimbangkan kontribusi tiap tugas.

Secara keseluruhan, arsitektur CNN-LSTM berbasis MTL ini dirancang untuk menghasilkan representasi bersama yang dapat mendukung ketiga tugas sekaligus. Dengan demikian, model diharapkan lebih akurat, efisien, dan konsisten dibandingkan pendekatan *single-task* atau pipeline modular.

3.1.3 Workflow Penelitian

Tahapan dalam penelitian ini akan dilakukan dalam beberapa Langkah sistematis berikut:

1. Studi Literatur

Menggunakan pendekatan *Systematic Literature Review (SLR)* untuk mengidentifikasi tren penelitian terkini, metode yang sering digunakan, serta kelemahan pendekatan sebelumnya. Dua sumber utama adalah *Systematic Review MTL* dan *Digital Image-Based Detection Review*.

2. Pengumpulan Data

Dataset berupa citra RGB keloid dari pasien. Setiap sampel dilengkapi dengan marker skala untuk mengonversi ukuran piksel menjadi cm^2 . Data disusun dalam bentuk time-series (2 s.d 4 frame per pasien) untuk merepresentasikan perkembangan keloid dari waktu ke waktu.

3. Pra-pemrosesan Data

Normalisasi ke rentang $[0,1]$, resizing ke 224×224 piksel, dan augmentasi (rotasi, flipping, zoom, penyesuaian kecerahan). Ekstraksi warna dominan menggunakan clustering (misalnya K-Means) untuk mendukung cabang analisis colorimetry.

4. Perancangan Model CNN-LSTM MTL


Model dirancang sebagai arsitektur end-to-end dengan *shared encoder* CNN dan *temporal sequence* LSTM, serta tiga cabang output multi-task.

5. Pelatihan Model

Optimizer Adam dengan learning rate scheduling, batch size 16–32, serta early stopping untuk mencegah overfitting. Loss dari ketiga cabang digabungkan menggunakan strategi uncertainty weighting agar pembelajaran lebih seimbang.

6. Evaluasi

Model dievaluasi dengan metrik tugas spesifik (Dice, IoU, MAE, RMSE, MSE) dan dibandingkan dengan baseline *single-task* serta pengukuran manual (ImageJ). Validasi luas luka juga dilakukan menggunakan ImageJ sebagai metode manual konvensional untuk memastikan perbandingan dengan standar penelitian medis. Alur metodologi penelitian ditunjukkan pada Gambar 3.1.



Gambar 3.1 Diagram Workflow Penelitian

3.1.4 Alur Kerja Segmentasi Menggunakan SAM

Pada penelitian ini, *Segment Anything Model* (SAM) digunakan pada tahap pra-pemrosesan data untuk menghasilkan mask segmentasi luka keloid secara semi-otomatis. SAM tidak digunakan sebagai model utama dalam proses pelatihan, melainkan berperan sebagai alat bantu anotasi untuk meningkatkan konsistensi dan efisiensi pembuatan label segmentasi.

Proses segmentasi dengan SAM dimulai dengan input citra RGB luka keloid ke dalam *image encoder* berbasis *Vision Transformer* (ViT). Pengguna memberikan *prompt* berupa *bounding box* atau titik awal pada area luka, yang kemudian diproses oleh prompt encoder untuk menghasilkan embedding tambahan. *Mask decoder* selanjutnya menghasilkan *mask* segmentasi luka keloid yang digunakan sebagai *ground truth* pada tahap pelatihan model CNN-LSTM-MTL.

Mask hasil SAM kemudian melalui proses verifikasi visual dan penyempurnaan manual apabila diperlukan, sebelum digunakan sebagai label segmentasi pada dataset penelitian. Dengan pendekatan ini, proses anotasi dapat dilakukan secara lebih cepat dan konsisten dibandingkan anotasi manual sepenuhnya, tanpa mengorbankan kualitas *mask* yang dihasilkan (Kirillov et al., 2023).


3.2 DESAIN SISTEM

3.2.1 Arsitektur Sistem

Perancangan Arsitektur sistem yang diusulkan dalam penelitian ini dirancang untuk memproses citra keloid secara *end-to-end* menggunakan pendekatan *Multi-Task Learning* (MTL) berbasis CNN-LSTM. Tujuan utamanya adalah agar model mampu melakukan tiga tugas utama segmentasi area keloid, pengukuran luasan luka, dan analisis warna (*colorimetry*) secara simultan dalam satu kerangka kerja terpadu.

Sistem ini menggunakan pendekatan *Hard Parameter Sharing*, di mana seluruh tugas berbagi *encoder* yang sama (CNN-LSTM) sebelum bercabang ke masing-masing output. Pendekatan ini dipilih karena lebih efisien secara komputasi dan dapat meningkatkan generalisasi antar-tugas melalui representasi fitur bersama. Arsitektur

sistem secara keseluruhan ditunjukkan pada Gambar 3.2, yang menggambarkan hubungan antar-layer dari tahap input hingga ketiga *output multi-task*.



Gambar 3.2 Diagram Arsitektur CNN-LSTM-MTL

Secara umum, arsitektur sistem terdiri atas enam komponen utama, yaitu input layer, CNN *encoder*, LSTM layer, *shared feature representation*, *multi-task output branches*, serta mekanisme penggabungan loss dan optimasi.

1. Input Layer

Lapisan input menerima urutan citra RGB luka keloid dalam bentuk time-series, yang merepresentasikan perkembangan luka pasien dari waktu ke waktu. Setiap pasien memiliki 2 hingga 4 frame citra, tergantung jumlah kunjungan klinis yang tersedia.

Setiap citra dinormalisasi dan direpresentasikan dalam bentuk tensor berukuran $224 \times 224 \times 3$, menyesuaikan dengan dimensi input standar pada arsitektur ResNet50 *pretrained ImageNet*. Penyusunan data dalam bentuk sekuens waktu memungkinkan sistem mempelajari tidak hanya karakteristik spasial luka pada satu waktu, tetapi juga dinamika perubahan morfologi dan warna luka secara longitudinal.

2. Encoder CNN ResNet50

Ekstraksi fitur spasial dilakukan menggunakan ResNet50 sebagai backbone CNN utama. ResNet50 dipilih karena memiliki struktur residual *block* yang memungkinkan pembelajaran jaringan dalam tanpa mengalami permasalahan *vanishing gradient*, serta telah terbukti efektif dalam berbagai aplikasi analisis citra medis. Model ResNet50 yang digunakan memanfaatkan bobot *pretrained ImageNet*, yang membantu mempercepat konvergensi pelatihan dan meningkatkan stabilitas model, terutama pada kondisi keterbatasan data medis. Keluaran CNN berupa *feature map* spasial berdimensi tinggi yang merepresentasikan tekstur jaringan, kontur luka, dan distribusi warna kulit di sekitar area keloid.

3. LSTM Layer

Lapisan *Long Short-Term Memory* (LSTM) digunakan untuk mempelajari hubungan temporal antar-frame citra pasien. Setiap fitur spasial yang dihasilkan CNN diubah menjadi sekuens fitur waktu, lalu dimasukkan ke dalam unit LSTM. LSTM berfungsi untuk menangkap pola perubahan ukuran dan warna keloid antar waktu, misalnya peningkatan area atau pergeseran rona warna yang menandakan fase inflamasi atau maturasi jaringan. Output dari LSTM berupa vektor representasi spasial-temporal yang akan menjadi masukan bagi tiga cabang output multi-tugas.

4. Shared Feature Representation Hard Parameter Sharing

Keluaran LSTM berperan sebagai shared feature representation yang digunakan bersama oleh seluruh tugas dalam skema *Multi-Task Learning*. Pada tahap ini,

tidak terdapat pemisahan parameter antar tugas, sehingga seluruh informasi spasial dan temporal yang telah dipelajari dimanfaatkan secara kolektif.

Pendekatan *Hard Parameter Sharing* ini memungkinkan terjadinya *cross-task learning*, di mana informasi yang relevan untuk segmentasi area luka juga membantu proses estimasi luasan dan analisis warna. Selain itu, strategi ini secara efektif menekan jumlah parameter model, sehingga meningkatkan kemampuan generalisasi dan stabilitas pelatihan.

5. Multi-Task Output Branches

Setelah melalui tahap ekstraksi fitur spasial oleh CNN berbasis ResNet50 dan pemodelan dinamika temporal menggunakan *Long Short-Term Memory* (LSTM), representasi fitur bersama (*shared feature representation*) selanjutnya dialirkan ke tiga cabang tugas (*task-specific heads*) yang saling terkait dalam kerangka *multi-task learning*:

- a. Cabang Segmentasi Area Keloid: dirancang untuk menghasilkan *binary mask* area luka keloid pada setiap *time-step* menggunakan *CNN-based decoder head* dengan mekanisme *upsampling* bertahap. *Decoder* ini berfungsi untuk mengembalikan resolusi spasial fitur hasil *encoder* tanpa menerapkan *skip connection*, sehingga tidak membentuk arsitektur encoder-decoder U-Net. ResNet50 digunakan sebagai *shared encoder* untuk mengekstraksi representasi spasial yang kaya dan konsisten pada seluruh tugas. Pendekatan ini memungkinkan pemanfaatan *cross-task feature sharing* pada tingkat representasi awal, sebagaimana dilaporkan pada studi sebelumnya. Fungsi *loss* yang digunakan pada cabang ini adalah kombinasi *Binary Cross-Entropy* dan *Dice Loss*, yang bertujuan untuk memaksimalkan kesesuaian antara prediksi segmentasi dan *ground truth*, khususnya pada area luka dengan bentuk tidak beraturan.
- b. Cabang Regresi Luas Luka: memanfaatkan representasi fitur temporal hasil LSTM yang telah diringkas melalui *global average pooling* pada setiap *time-step*. Representasi ini selanjutnya diproses menggunakan *fully connected*

layer untuk memprediksi nilai luas luka dalam satuan cm² pada setiap waktu pengamatan. Cabang ini tidak menggunakan hasil segmentasi sebagai masukan eksplisit, melainkan mengandalkan representasi fitur bersama yang dipelajari secara simultan selama proses *multi-task learning*. Pendekatan ini memungkinkan konsistensi implisit antara informasi bentuk spasial dan estimasi luasan melalui mekanisme *hard parameter sharing*. Evaluasi performa regresi dilakukan menggunakan metrik *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE).

- c. Cabang Analisis Warna (*Colorimetry*): menggunakan *dense layer* untuk melakukan regresi nilai warna luka keloid pada area hasil segmentasi. Analisis warna dilakukan menggunakan ruang warna CIELAB (L*, a*, b*), dengan fokus utama pada komponen L* sebagai indikator tingkat pigmentasi dan komponen a* sebagai indikator eritema. Nilai warna diperoleh dengan menghitung nilai rata-rata komponen CIELAB pada area luka hasil segmentasi, tanpa penerapan teknik *clustering* warna. Pendekatan ini memungkinkan analisis warna dilakukan secara kuantitatif dan relatif stabil terhadap variasi pencahayaan. Fungsi *loss* yang digunakan pada cabang ini adalah *Mean Squared Error* (MSE) antara nilai CIELAB hasil prediksi model dan nilai referensi (*ground truth*).

Arsitektur gabungan CNN-LSTM-MTL ini memungkinkan pembelajaran lintas-tugas (*cross-task learning*), di mana informasi spasial dari segmentasi dapat membantu regresi luas luka dan memperkuat prediksi warna. Pendekatan ini diadopsi berdasarkan temuan dalam literatur terkini, yang menunjukkan bahwa integrasi spasial-temporal melalui CNN-LSTM memberikan peningkatan signifikan pada performa analisis citra medis longitudinal.

6. Penggabungan *Loss* dan Optimasi

Ketiga cabang output dilatih secara simultan melalui *joint optimization*, dengan total *loss* dirumuskan sebagai:

$$\mathcal{L}_{total} = \lambda_1 \times \mathcal{L}_{Dice} + \lambda_2 \times \mathcal{L}_{Regresi} + \lambda_3 \times \mathcal{L}_{Color}$$

Bobot $\lambda_1, \lambda_2, \lambda_3$ diatur menggunakan pendekatan *uncertainty weighting* (Kendall et al., 2018), yang memungkinkan model menyesuaikan kontribusi masing-masing tugas secara dinamis berdasarkan tingkat kesulitannya. Pendekatan ini memastikan bahwa tidak ada satu tugas yang mendominasi proses pembelajaran, sekaligus menjaga stabilitas pelatihan model MTL.

7. Output Akhir dan Interpretasi

Hasil akhir model mencakup tiga keluaran utama:

- *Mask* segmentasi area luka.
- Nilai numerik luas luka dalam cm^2 .
- Rasio warna Lab dominan dari area luka.

Ketiga hasil ini kemudian ditampilkan dalam antarmuka aplikasi berbasis *Dash*, memungkinkan pengguna (dokter atau peneliti) untuk memantau perubahan ukuran dan warna keloid pasien secara longitudinal melalui grafik dan *overlay* visual.

3.2.2 Representasi Data

Data penelitian direpresentasikan dalam empat aspek utama untuk mendukung analisis spasial, temporal, dan klinis:

1. Citra RGB

Setiap citra keloid direpresentasikan sebagai tensor $224 \times 224 \times 3$, menyesuaikan dengan input ResNet50 *pretrained ImageNet*. Representasi ini memungkinkan model mengenali pola spasial seperti bentuk, kontur, dan tekstur jaringan.

2. Informasi Warna

Informasi warna luka keloid diperoleh melalui analisis warna pada area luka hasil segmentasi menggunakan ruang warna CIELAB (L^*, a^*, b^*). Nilai rata-rata komponen L^* digunakan untuk merepresentasikan tingkat kecerahan atau

pigmentasi jaringan, sedangkan komponen a^* digunakan sebagai indikator tingkat eritema. Analisis ini dimanfaatkan sebagai indikator kuantitatif untuk mengamati perubahan karakteristik warna luka keloid pada berbagai fase perkembangan jaringan secara longitudinal.

3. Luasan Area Luka

Luas keloid dihitung dalam cm^2 melalui konversi piksel hasil segmentasi dengan *fiducial marker* sebagai skala. Representasi ini memastikan hasil prediksi memiliki makna klinis yang terukur.

4. *Time-Series* Citra Pasien

Setiap pasien direpresentasikan dengan urutan 2 s.d 4 citra pada interval waktu berbeda. Format ini memungkinkan model (LSTM) menangkap pola longitudinal, seperti pertumbuhan bertahap atau perubahan warna dari waktu ke waktu.

Secara keseluruhan, kombinasi representasi spasial, warna, kuantitatif, dan temporal ini dirancang agar model CNN-LSTM berbasis MTL mampu memberikan analisis yang akurat sekaligus relevan secara klinis.

3.2.3 Persiapan Dataset

Dataset yang digunakan dalam penelitian ini terdiri atas 145 citra RGB luka keloid yang berasal dari 42 pasien. Setiap pasien memiliki 2 s.d 4 citra yang diambil pada interval waktu berbeda, sehingga membentuk data time-series perkembangan luka keloid.

Seluruh data disusun berdasarkan struktur direktori per pasien dan per bulan, dan digunakan secara berurutan sesuai kronologi pengambilan citra.

Pada penelitian ini tidak diterapkan pembagian dataset secara eksplisit ke dalam *training set*, *validation set*, dan *testing set* dengan rasio tertentu. Hal ini dikarenakan fokus penelitian adalah pada pemodelan perkembangan luka keloid berbasis time-series per pasien, sehingga pemisahan data secara acak berpotensi merusak keterkaitan temporal antar bulan pengamatan.

Proses pelatihan model dilakukan dengan memanfaatkan seluruh data time-series yang tersedia, di mana model mempelajari pola spasial dan temporal dari citra luka keloid secara berurutan.

3.2.4 Implementasi Antarmuka Aplikasi

Implementasi penelitian ini dilakukan menggunakan kombinasi perangkat lunak, perangkat keras, dan framework *deep learning* yang disesuaikan dengan kebutuhan analisis citra medis berbasis CNN–LSTM Multi-Task Learning (MTL). Tahapan implementasi dijelaskan sebagai berikut:

1. Bahasa Pemrograman

Penelitian ini menggunakan Python sebagai bahasa utama karena memiliki dukungan pustaka yang luas untuk *machine learning* dan *computer vision*, seperti TensorFlow, Keras, dan OpenCV. Selain itu, Python memiliki komunitas riset aktif dan dokumentasi ekstensif yang memudahkan proses pengembangan dan *debugging*.

2. Framework dan Library

- TensorFlow/Keras digunakan untuk membangun dan melatih arsitektur CNN–LSTM–MTL.

Keras mempermudah perancangan arsitektur *multi-task*, sedangkan TensorFlow memungkinkan komputasi paralel menggunakan GPU, mempercepat proses pelatihan model.

- OpenCV dimanfaatkan untuk tahap pra-pemrosesan citra, meliputi *resizing*, *normalisasi*, *augmentasi*, dan *ekstraksi fitur warna (color clustering)*.
- Pandas dan NumPy digunakan untuk manajemen data numerik, sedangkan Matplotlib/Plotly digunakan untuk visualisasi hasil pelatihan dan inferensi.

3. Perangkat Keras

Pelatihan model dilakukan pada komputer dengan GPU yang mendukung CUDA untuk mempercepat komputasi *deep learning*. Penggunaan GPU memperpendek waktu

pelatihan secara signifikan dibandingkan hanya menggunakan CPU, terutama pada dataset *time-series* yang memerlukan propagasi berurutan dalam LSTM.

4. Dataset dan Keamanan Data

Dataset berisi citra RGB keloid dengan fiducial marker sebagai acuan skala untuk penghitungan luasan luka. Setiap citra disertai label *ground truth* berupa *mask segmentasi* yang dibuat oleh pakar dermatologi menggunakan ImageJ. Seluruh data pasien telah melalui proses anonimisasi, sehingga tidak mengandung informasi identitas pribadi sesuai dengan prinsip *data privacy and ethical research*.

5. Augmentasi Data

Pada penelitian ini, augmentasi data difokuskan pada stabilisasi karakteristik citra medis guna mengurangi variasi non-klinis yang berasal dari perbedaan kondisi pengambilan gambar. Augmentasi dilakukan pada aspek intensitas dan representasi citra, tanpa mengubah struktur geometris objek luka, sehingga konsistensi temporal antar bulan tetap terjaga. Bentuk augmentasi yang digunakan meliputi:

1. Normalisasi Eksposur Citra

Normalisasi eksposur diterapkan untuk menyamakan distribusi intensitas dan warna antar citra yang diambil pada kondisi pencahayaan berbeda. Proses ini bertujuan mengurangi bias pencahayaan dan meningkatkan kestabilan proses segmentasi serta analisis warna.

2. Standarisasi Resolusi Citra

Seluruh citra diubah ke ukuran 224×224 piksel agar sesuai dengan kebutuhan input arsitektur ResNet50. Standarisasi ini memastikan konsistensi dimensi data dan efisiensi pemrosesan model CNN-LSTM.

3. Normalisasi Nilai Piksel

Nilai intensitas piksel dinormalisasi ke dalam rentang $[0,1]$ untuk meningkatkan stabilitas pelatihan model dan mempercepat proses konvergensi selama training.

Pendekatan augmentasi ini dipilih karena mempertahankan bentuk dan posisi luka keloid secara utuh, yang sangat penting dalam analisis time-series citra medis. Dengan demikian, perubahan yang dipelajari model lebih merepresentasikan perkembangan klinis luka dibandingkan artefak akibat transformasi geometris.

.6. Implementasi Aplikasi (*Proof-of-Concept*)

Sebagai bentuk *proof-of-concept*, sistem ini akan diimplementasikan dalam bentuk aplikasi berbasis web interaktif menggunakan Dash (Python Framework). Aplikasi ini ditujukan untuk pengguna seperti dokter atau peneliti, yang dapat mengunggah citra keloid RGB dan memperoleh hasil analisis secara otomatis.

Fungsi utama aplikasi meliputi:

1. Dash Layout:

Antarmuka interaktif dengan komponen *file uploader*, tombol *process*, dan *output display* hasil segmentasi.

2. Callback Function:

Menjalankan model CNN–LSTM–MTL untuk *real-time inference* dan menampilkan hasil prediksi.

3. Visualization Module:

Menampilkan *overlay mask* hasil segmentasi, grafik luasan luka (cm²) terhadap waktu, serta distribusi rasio warna Lab hasil analisis *colorimetry*.

Implementasi berbasis Dash dipilih karena:

- Ringan dan mudah diintegrasikan dengan *Python/TensorFlow*;
- Mendukung visualisasi data interaktif (*real-time plotting*);
- Dapat diakses melalui browser tanpa instalasi tambahan, sehingga cocok untuk validasi klinis berbasis web.

Aplikasi ini sekaligus menjadi media validasi klinis interaktif yang memperlihatkan hasil segmentasi, luasan, dan warna secara kuantitatif.

3.2.5 Strategi Pelatihan

Pelatihan dilakukan secara *end-to-end joint optimization*, di mana loss dari ketiga cabang dihitung bersamaan. Pembobotan loss disesuaikan berdasarkan hasil validasi. Strategi ini diadopsi dari penelitian dalam *Systematic Review MTL*, yang menunjukkan bahwa pembelajaran bersama (*joint learning*) memberikan stabilitas lebih baik dibandingkan *sequential training*.

3.2.6 Spesifikasi Perangkat Keras dan Perangkat Lunak

Proses penelitian ini dilakukan menggunakan kombinasi perangkat keras lokal dan layanan komputasi berbasis cloud.

- Perangkat lokal: Laptop dengan spesifikasi prosesor Intel Core i5-6200U @ 2.30 GHz, RAM 16 GB, sistem operasi Windows 10 (64-bit). Perangkat ini digunakan terutama untuk tahap pra-pemrosesan data dan eksperimen ringan.
- Layanan komputasi cloud: Google Colab Pro, Kaggle Notebook, dan Paperspace Gradient. Ketiga platform ini dipilih karena menyediakan GPU NVIDIA (misalnya Tesla T4, V100, atau RTX A100) yang mendukung CUDA, sehingga mempercepat proses pelatihan model deep learning.
- Perangkat lunak: Python 3.10, TensorFlow/Keras sebagai framework utama deep learning, OpenCV untuk pemrosesan citra, dan scikit-learn untuk analisis metrik.

3.2.7 Validasi Klinis

Selain evaluasi kuantitatif berbasis metrik (Dice Score, IoU, MAE, RMSE, MSE), hasil prediksi model akan divalidasi oleh dokter spesialis kulit yang memiliki pengalaman klinis dalam mendiagnosis dan mengevaluasi keloid. Validasi klinis dilakukan pada tiga aspek utama yang relevan dengan tujuan penelitian, yaitu segmentasi, pengukuran luas, dan analisis warna.

- Pada tugas segmentasi, hasil prediksi dibandingkan dengan anotasi manual yang dibuat oleh klinisi.
- Pada tugas pengukuran luas, nilai prediksi dibandingkan dengan hasil pengukuran konvensional menggunakan perangkat lunak ImageJ, lalu diverifikasi oleh klinisi.
- Pada tugas analisis warna, distribusi warna hasil prediksi dinilai kesesuaiannya dengan kondisi nyata berdasarkan penilaian klinisi.

3.2.8 Strategi Pembobotan *Loss*

Karena penelitian ini menggunakan pendekatan *Multi-Task Learning* (MTL) dengan tiga tugas (segmentasi, regresi luas, dan analisis warna), diperlukan strategi untuk menyeimbangkan kontribusi setiap fungsi *loss*.

Tiga strategi pembobotan yang dipertimbangkan adalah:

1. *Equal Weighting*: memberikan bobot yang sama pada setiap *loss* (misalnya 1:1:1). Strategi ini sederhana, tetapi berpotensi membuat salah satu task mendominasi.
2. *Manual Tuning*: menetapkan bobot berbeda (misalnya 0.5 untuk segmentasi, 1 untuk regresi luas, 1 untuk analisis warna) berdasarkan hasil validasi. Strategi ini digunakan pada tahap awal eksperimen.
3. *Uncertainty Weighting* (Kendall et al., 2018): membiarkan model mempelajari bobot *loss* secara otomatis berdasarkan tingkat ketidakpastian masing-masing task. Strategi ini dipilih pada tahap akhir penelitian karena mampu menyesuaikan bobot secara dinamis, sehingga memberikan hasil lebih stabil.

Dengan strategi ini, model diharapkan dapat mencapai keseimbangan performa antar-tugas, tanpa mengorbankan akurasi salah satu tugas.

3.3 RENCANA PENGUJIAN DAN EVALUASI

3.3.1 Skema Pengujian

Skema pengujian pada penelitian ini dirancang untuk mengevaluasi kinerja sistem secara menyeluruh dalam melakukan segmentasi luka keloid, pengukuran luasan luka, serta analisis warna berbasis citra medis.

Pada tahap pengembangan model, data citra luka keloid digunakan untuk proses pelatihan dan validasi model CNN–LSTM–Multi-Task Learning. Data validasi dimanfaatkan untuk memantau proses pelatihan dan mencegah terjadinya overfitting, sehingga diperoleh model dengan performa terbaik. Model hasil pelatihan kemudian disimpan dalam bentuk berkas .h5.

Pada tahap pengujian, penelitian ini tidak melakukan evaluasi model menggunakan dataset uji terpisah secara eksplisit. Sebaliknya, pengujian difokuskan pada pengujian fungsional dan performa sistem, yaitu dengan menerapkan model terlatih pada data pasien untuk menghasilkan keluaran segmentasi, luasan luka dalam satuan cm^2 , dan nilai warna luka.

Pendekatan ini dipilih karena tujuan utama penelitian adalah mengembangkan sistem analisis luka keloid berbasis time-series, bukan melakukan perbandingan performa model klasifikasi atau segmentasi secara murni. Dengan demikian, hasil pengujian lebih menekankan pada konsistensi keluaran sistem, keterpaduan antar tugas (multi-task), serta kesesuaian hasil pengukuran dengan pengukuran manual menggunakan perangkat lunak ImageJ.

3.3.2 Skenario Simulasi

Untuk memberikan pemahaman menyeluruh mengenai keunggulan MTL CNN-LSTM, dibuat empat skenario simulasi:

- Skenario 1: Baseline segmentasi Single-Task CNN

Skenario ini mengevaluasi kinerja segmentasi area keloid menggunakan arsitektur CNN berbasis ResNet50 tanpa penerapan Multi-Task Learning. Model hanya

dilatih untuk menghasilkan mask segmentasi pada setiap time-step, tanpa melibatkan tugas regresi luas luka maupun analisis warna. Skenario ini digunakan sebagai pembandingan untuk menilai kontribusi pendekatan Multi-Task Learning terhadap peningkatan performa segmentasi..

- Skenario 2: Regresi luas luka *Single-Task*

Pada skenario ini, estimasi luas luka keloid dilakukan sebagai tugas tunggal menggunakan model berbasis CNN–LSTM tanpa skema Multi-Task Learning. Model menerima urutan citra RGB sebagai masukan dan menghasilkan prediksi nilai luas luka (dalam cm²) pada setiap waktu pengamatan. Segmentasi luka tidak dipelajari maupun diprediksi oleh model, melainkan hanya digunakan pada tahap anotasi untuk memperoleh nilai *ground truth* luas luka. Skenario ini bertujuan untuk mengevaluasi kinerja regresi luas luka ketika pembelajaran difokuskan pada satu tugas tanpa dukungan pembelajaran lintas-tugas (*cross-task learning*).

- Skenario 3: Prediksi warna *Single-Task Color Regression*

Pada skenario ini, analisis warna luka keloid dilakukan sebagai tugas tunggal menggunakan model berbasis CNN–LSTM untuk memprediksi nilai warna pada ruang warna CIELAB, khususnya komponen L* sebagai indikator pigmentasi dan a* sebagai indikator eritema. Model menerima urutan citra RGB sebagai masukan dan menghasilkan prediksi nilai warna pada setiap waktu pengamatan. Nilai *ground truth* warna diperoleh dari rata-rata komponen CIELAB pada citra ROI luka keloid berlatar putih. Pada skenario ini, model tidak melibatkan proses segmentasi maupun estimasi luasan luka, sehingga pembelajaran sepenuhnya difokuskan pada tugas analisis *colorimetry*. Skenario ini digunakan sebagai baseline untuk mengevaluasi kinerja analisis warna *single-task* serta membandingkannya dengan pendekatan *Multi-Task Learning* dalam konteks integrasi segmentasi, regresi luasan, dan analisis warna.

- Skenario 4: MTL CNN-LSTM end-to-end

Skenario utama penelitian ini, di mana segmentasi, regresi luas, dan prediksi warna dilakukan secara bersamaan dalam satu arsitektur *end-to-end*. Skenario ini

diharapkan memberikan hasil terbaik berkat adanya *shared representation* antar-tugas.

Dengan adanya empat skenario ini, penelitian dapat membandingkan hasil kerja tiap metode, baik yang berdiri sendiri maupun yang terintegrasi, sehingga dapat ditarik kesimpulan yang lebih kuat mengenai manfaat MTL.

3.3.3 Metrik Evaluasi

Pengujian model akan dilakukan dengan menggunakan metrik evaluasi yang disesuaikan dengan masing-masing tugas, yaitu:

- **Segmentasi:** *Dice Score* dan *Intersection over Union (IoU)*, yang merupakan metrik standar dalam evaluasi segmentasi medis. Nilai yang lebih tinggi menunjukkan kemampuan model yang lebih baik dalam mendeteksi area keloid.
- **Regresi Luas Luka:** *Mean Absolute Error (MAE)* dan *Root Mean Square Error (RMSE)*. MAE menggambarkan rata-rata kesalahan dalam satuan cm^2 , sedangkan RMSE lebih sensitif terhadap kesalahan yang besar.
- **Colorimetry:** *Mean Squared Error (MSE)* pada komponen warna L (pigmentasi) dan a (eritema) pada ruang warna LAB, karena metrik ini mampu mengukur deviasi antara nilai warna hasil prediksi model dan nilai referensi secara kuantitatif.
- **Kinerja Keseluruhan Sistem:** stabilitas *loss* selama pelatihan, waktu pelatihan, serta efisiensi komputasi. Aspek ini penting karena MTL dituntut tidak hanya akurat, tetapi juga efisien dalam pemrosesan.

Pemilihan metrik evaluasi ini didasarkan pada rekomendasi *Systematic Review on Multi-Task Learning* dan *Digital Image-Based Detection Review*, yang menekankan bahwa kombinasi antara metrik kuantitatif dan indikator kinerja komputasional merupakan standar utama dalam mengevaluasi model berbasis citra medis.

3.3.4 Proses Pengujian dan Analisis Data

Pengujian dilakukan secara bertahap untuk menilai performa model baik secara kuantitatif maupun kualitatif. Langkah-langkahnya meliputi:

1. Pelatihan Model

Model CNN-LSTM-MTL dilatih menggunakan data *training*, dengan penerapan validasi untuk mencegah *overfitting*. Pendekatan ini memastikan model belajar secara optimal sekaligus mempertahankan kemampuan generalisasi.

2. Evaluasi Dataset Uji

Kemampuan model diuji pada dataset independen untuk menilai seberapa baik model dapat menggeneralisasi pada data yang belum pernah dilihat sebelumnya. Evaluasi ini menjadi tolok ukur penting efektivitas MTL.

3. Perbandingan Skenario

Hasil yang diperoleh dari model MTL kemudian dibandingkan dengan beberapa pendekatan lain, termasuk baseline *single-task* dan metode manual menggunakan ImageJ. Perbandingan ini membantu menilai keunggulan dan kelemahan MTL secara komprehensif.

4. Analisis Kuantitatif

Performa model diukur menggunakan berbagai metrik kuantitatif, seperti Dice, IoU, MAE, RMSE, dan MSE, serta dilengkapi evaluasi efisiensi komputasi. Analisis ini memberikan gambaran objektif mengenai akurasi dan kecepatan model.

5. Analisis Kualitatif

Hasil segmentasi dan prediksi divisualisasikan melalui overlay segmentasi, grafik regresi luas, dan distribusi warna. Visualisasi ini kemudian diverifikasi oleh klinisi untuk memastikan kesesuaian dengan interpretasi medis.

6. Penarikan Kesimpulan

Hasil kuantitatif dan kualitatif digabungkan untuk menilai keunggulan serta keterbatasan MTL dalam aplikasi medis. Kesimpulan ini menjadi dasar rekomendasi bagi pengembangan model selanjutnya.

3.3.5 Pengujian Kinerja MTL dan ImageJ

Selain evaluasi akurasi, penelitian ini juga melakukan pengujian kinerja untuk menilai efisiensi komputasi model dibandingkan dengan metode konvensional (ImageJ). Untuk mengukur performa sistem yang dikembangkan, dilakukan pengujian terhadap waktu pemrosesan (*processing time*) dan variasi data uji.

- Uji waktu proses: membandingkan durasi inferensi per citra antara model MTL (*end-to-end*) dan metode konvensional berbasis ImageJ (manual pipeline).
- Variasi data uji: meliputi variasi pencahayaan, orientasi, dan ukuran luka dari tiga kategori pasien.
- Metode pengukuran: waktu eksekusi diukur menggunakan *Python time module* untuk model MTL dan *timestamp* proses pada ImageJ.
- Output evaluasi: rata-rata waktu proses per citra (detik) dan rasio percepatan (*speedup ratio*) antara MTL dan ImageJ.

Dengan pengujian ini, performa MTL dapat dinilai tidak hanya dari segi akurasi klinis, tetapi juga dari efisiensi waktu pemrosesan yang penting untuk penerapan dalam praktik nyata.

BAB 4

IMPLEMENTASI DAN PENGUJIAN SISTEM


Pada bab IV ini, setelah tahapan perancangan diselesaikan, dilakukan implementasi sistem yang telah dikembangkan. implementasi tersebut mencakup penerapan metode CNN–LSTM–Multi-Task Learning pada sistem analisis luka keloid, serta pengujian fungsionalitas dan kinerja sistem berdasarkan data yang digunakan dalam penelitian segmentasi, pengukuran luasan, dan colorimetry pada scar keloid menggunakan Multi-Task Learning berbasis CNN dan LSTM.

4.1 BLOK DIAGRAM

Blok diagram sistem pada Gambar 4.1 merepresentasikan alur implementasi sistem yang diterapkan dalam penelitian ini. Diagram tersebut menggambarkan rangkaian proses aktual, mulai dari penerimaan data citra luka keloid hingga penyajian hasil analisis dalam bentuk visualisasi pada dashboard.

Blok diagram ini disusun untuk memperjelas hubungan antar tahapan pemrosesan yang telah diimplementasikan, sekaligus menunjukkan aliran data menuju tiga keluaran utama sistem, yaitu segmentasi luka, pengukuran luasan luka, dan analisis warna luka. Secara umum, sistem yang diimplementasikan terdiri dari enam blok utama:

1. Input data citra luka keloid
2. Prapemrosesan data
3. Pembentukan data time-series
4. Implementasi Sistem CNN–LSTM–MTL
5. Proses inferensi
6. Visualisasi hasil



Gambar 4.1 Blok diagram

4.1.1 Input Data Citra Luka Keloid

Pada tahap implementasi, sistem menerima data berupa citra medis luka keloid mentah (*raw image*) yang diperoleh dari pasien secara berkala dengan interval pengambilan citra bulanan. Setiap pasien memiliki sekumpulan citra yang tersusun berdasarkan urutan waktu pengamatan.



Gambar 4.2 Citra medis luka keloid mentah (*raw image*)

Citra disimpan dalam format RGB dengan resolusi yang bervariasi sesuai dengan kondisi akuisisi. Seluruh citra dikelompokkan berdasarkan identitas pasien dan bulan pengamatan dalam struktur direktori yang telah ditentukan. Pengelompokan ini digunakan secara langsung oleh sistem untuk membentuk data *time-series* pada tahap selanjutnya.

4.1.2 Prapemrosesan Data

Tahap prapemrosesan dilakukan untuk menyiapkan citra agar sesuai dengan kebutuhan sistem inferensi. Proses prapemrosesan yang diimplementasikan meliputi:

1. Cropping area luka dan penggaris untuk memperoleh area yang relevan.

Citra luka keloid mentah (*raw image*) terlebih dahulu melalui proses *cropping* secara manual untuk mengambil area luka keloid dan penggaris sebagai referensi skala pengukuran. Proses ini dilakukan untuk menghilangkan bagian citra yang tidak relevan sehingga area luka dan penggaris terlihat lebih jelas dan konsisten.


Hasil *cropping* disimpan dalam berkas “image.jpg” dan digunakan sebagai citra dasar pada tahap prapemrosesan selanjutnya. Berikut ditampilkan contoh citra keloid yang telah melalui proses *cropping*.



Gambar 4.3 Citra medis luka keloid *cropping*

2. Normalisasi eksposur untuk menyamakan karakteristik pencahayaan antar citra.

Normalisasi eksposur dilakukan untuk menyelaraskan karakteristik intensitas dan warna antar citra luka keloid yang diperoleh pada kondisi pencahayaan berbeda. Proses ini bertujuan mengurangi pengaruh variasi pencahayaan sehingga citra memiliki tampilan visual yang lebih konsisten. Citra hasil normalisasi disimpan dengan nama “image_exposure.jpg” dan digunakan sebagai acuan utama pada proses segmentasi luka, pembentukan data, serta inferensi model. Berikut ditampilkan contoh citra keloid yang telah melalui proses normalisasi eksposur.



Gambar 4.4 Citra medis luka keloid *normalisasi exposure*



3. Segmentasi luka keloid untuk menghasilkan Mask biner area luka.

Segmentasi luka keloid dilakukan untuk menghasilkan mask biner area luka berdasarkan citra “image_exposure.jpg”. Proses segmentasi ini menghasilkan citra biner dengan nama “mask_keloid.png”, di mana area luka direpresentasikan oleh piksel putih (1) dan latar belakang oleh piksel hitam (0). *Mask* segmentasi ini diperoleh pada tahap pra-pemrosesan menggunakan *Segment Anything Model* (SAM) dan digunakan sebagai *ground truth* pada proses pelatihan cabang segmentasi model CNN-LSTM-Multi-Task Learning. Selain itu, *mask* ini juga berperan sebagai dasar perhitungan luasan luka serta sebagai pembatas area relevan pada analisis warna luka. *Mask* “mask_keloid.png” berfungsi sebagai representasi biner area luka dan tidak digunakan secara langsung sebagai citra visual untuk analisis warna. Contoh hasil segmentasi luka keloid ditunjukkan pada Gambar 4.5.

Normalisasi Exposure (Sebelum)



Mask Luka (Sesudah)




Gambar 4.5 Citra medis luka keloid *mask*

4. Pembentukan Citra Hasil Segmentasi Visual

Untuk keperluan visualisasi dan analisis warna luka, mask hasil segmentasi diaplikasikan pada citra hasil prapemrosesan sehingga hanya area luka keloid yang dipertahankan, sedangkan area di luar luka digantikan dengan latar belakang putih. Proses ini menghasilkan citra yang lebih fokus pada area luka dan

menghilangkan pengaruh visual dari latar belakang. Hasil proses ini disimpan dalam berkas “keloid_only_white.jpg” dan digunakan khusus untuk analisis kolorimetri luka keloid. Contoh citra hasil segmentasi visual ditunjukkan pada Gambar 4.6 berikut:



Gambar 4.6 citra medis luka keloid segmentasi visual


5. Penentuan skala piksel ke satuan cm menggunakan perangkat lunak ImageJ (Fiji).

Penentuan skala piksel ke satuan nyata dilakukan untuk memungkinkan pengukuran luasan luka keloid dalam satuan cm^2 . Skala konversi diperoleh menggunakan perangkat lunak Fiji (ImageJ) dengan mengukur panjang penggaris yang terdapat pada citra hasil *cropping*. Nilai skala ini merepresentasikan hubungan antara jumlah piksel dan satuan sentimeter. Nilai hasil pengukuran disimpan dalam berkas “scale.txt” dan digunakan pada proses pembentukan label luasan luka serta konversi hasil prediksi luasan dari satuan piksel ke cm^2 . Dengan demikian, nilai luasan luka yang dihasilkan sistem dapat diinterpretasikan dalam satuan fisik yang bermakna secara klinis.

Seluruh hasil prapemrosesan disimpan dan digunakan kembali pada tahap inferensi dan visualisasi hasil.

4.1.3 Pembentukan Data *Time-Series*

Citra hasil prapemrosesan disusun menjadi sekuens *time-series* berdasarkan urutan bulan pengamatan. Sistem menggunakan jumlah *time-step* tetap. Apabila data pada suatu bulan tidak tersedia, sistem menerapkan padding nol pada proses inferensi, sedangkan nilai kosong (NaN) ditampilkan pada tahap visualisasi. Berikut contoh gambar data pasien dari bulan 1 s.d bulan ke 4:



Gambar 4.7 Citra keloid *time series*

Pada penelitian ini, citra hasil prapemrosesan tidak hanya diperlakukan sebagai data statis, melainkan disusun menjadi rangkaian sekuens multitemporal (*time-series*) untuk merepresentasikan perkembangan keloid pasien dari bulan ke bulan. Pendekatan ini bertujuan untuk memungkinkan sistem mempelajari pola perubahan jaringan scar secara spasial dan temporal, seperti perubahan bentuk, luasan, serta karakteristik warna selama periode observasi.

Setiap pasien diamati dalam beberapa waktu pengambilan citra yang telah ditetapkan secara berurutan. Sistem menggunakan jumlah *time-step* tetap, yaitu empat bulan pengamatan, sesuai konfigurasi parameter berikut:

IMG_SIZE = 224 TIME_STEPS = 4

Dengan demikian, setiap sampel pasien direpresentasikan dalam bentuk sekuens:

$$X = I_1, I_2, I_3, I_4 \quad \dots (13)$$

di mana I_t merupakan citra pada bulan ke- t .

Pembentukan data time-series dilakukan pada tahap pemuatan dataset (data loader). Sistem melakukan iterasi untuk setiap pasien dan menyusun citra berdasarkan folder bulan pengamatan yang terstruktur sebagai berikut:

- month_01
- month_02
- month_03
- month_04

Proses ini diimplementasikan melalui loop time-step berikut:

```
for t in range(1, TIME_STEPS + 1):  
    month_dir = os.path.join(base_dir, patient, f'month_{t:02d}')
```

Pada setiap bulan pengamatan, sistem mengambil empat komponen data utama:

1. Citra utama RGB untuk input CNN
2. Mask ground-truth untuk segmentasi
3. Nilai luasan keloid dalam satuan cm^2
4. Informasi warna rata-rata hasil colorimetry pada ROI scar

Dalam kondisi nyata, tidak semua pasien memiliki data lengkap pada setiap bulan observasi. Oleh karena itu, penelitian ini menerapkan strategi padding nol (zero-padding) agar panjang sekuens tetap konsisten. Apabila data citra pada bulan tertentu tidak tersedia, maka sistem menggantinya dengan matriks nol pada proses inferensi, sehingga model tetap menerima input dengan dimensi yang seragam.

Implementasi padding dilakukan sebagai berikut:

```
else:  
    img = np.zeros((IMG_SIZE, IMG_SIZE, 3), dtype=np.float32)  
    mask = np.zeros((IMG_SIZE, IMG_SIZE), dtype=np.float32)  
    area_cm2 = 0.0  
    color = np.zeros(3, dtype=np.float32)
```

Strategi ini sesuai dengan prinsip time-series modeling pada deep learning, di mana sistem tetap mempertahankan struktur temporal meskipun terdapat missing data. Selain itu, nilai kosong (NaN) dapat ditampilkan pada tahap visualisasi untuk menunjukkan

bulan tanpa observasi, sementara pada tahap pelatihan sistem menggunakan padding nol agar tidak mengganggu proses komputasi.

Setelah seluruh bulan pengamatan diproses, data setiap pasien disusun menjadi array multitemporal. Data input dan target multi-task learning dibentuk seperti program berikut:

```
imgs.append(img)
masks.append(mask)
areas.append(area_cm2)
colors.append(color)
```

Kemudian seluruh sekuens dimasukkan ke dataset utama:

```
X.append(imgs)
Y_seg.append(masks)
Y_area.append(areas)
Y_color.append(colors)
```

Sehingga struktur akhir dataset menjadi:

- Input citra time-series:

$$\mathbf{X} \in \mathbb{R}^{Nx4x224x224x3} \quad \dots (14)$$

- Target segmentasi multibulan:

$$\mathbf{Y}_{seg} \in \mathbb{R}^{Nx4x224x224x1} \quad \dots (15)$$

- Target luasan temporal:

$$\mathbf{Y}_{area} \in \mathbb{R}^{Nx4x1} \quad \dots (16)$$

- Target warna temporal:

$$\mathbf{Y}_{color} \in \mathbb{R}^{Nx4x3} \quad \dots (17)$$

Berikut merupakan bagian program utama yang digunakan dalam pembentukan data time-series multitemporal:

```
def load_dataset(base_dir):
    X, Y_seg, Y_area, Y_color = [], [], [], []

    for patient in sorted(os.listdir(base_dir)):
        if not patient.startswith("PATIENT"):
            continue

        imgs, masks, areas, colors = [], [], [], []
        valid = 0

        for t in range(1, TIME_STEPS + 1):
            month_dir = os.path.join(base_dir, patient, f"month_{t:02d}")

            img_p = os.path.join(month_dir, "image_exposure.jpg")
            mask_p = os.path.join(month_dir, "mask_keloid.png")
            roi_p = os.path.join(month_dir, "keloid_white_bg.jpg")
            scale_p = os.path.join(month_dir, "scale.txt")

            if all(os.path.exists(p) for p in [img_p, mask_p, roi_p, scale_p]):

                # ===== INPUT CNN (RGB UTAMA)
                img = cv2.imread(img_p)
                img = cv2.cvtColor(img, cv2.COLOR_BGR2RGB)
                img = cv2.resize(img, (IMG_SIZE, IMG_SIZE))
                img = img.astype(np.float32) / 255.0

                # ===== MASK SEGMENTASI
                mask_orig = cv2.imread(mask_p, 0)
                mask_orig = (mask_orig > 0).astype(np.float32)
                mask = cv2.resize(mask_orig, (IMG_SIZE, IMG_SIZE))

                # ===== AREA (cm²)
                pixel_per_cm = float(open(scale_p).read().strip())
                area_pixel = np.sum(mask_orig)
                area_cm2 = area_pixel * (1.0 / pixel_per_cm) ** 2

                # ===== COLOR (ROI PUTIH)
                color = extract_color(roi_p)

                valid += 1

            else:
                img = np.zeros((IMG_SIZE, IMG_SIZE, 3), dtype=np.float32)
                mask = np.zeros((IMG_SIZE, IMG_SIZE), dtype=np.float32)
                area_cm2 = 0.0
```

```

        color = np.zeros(3, dtype=np.float32)

        imgs.append(img)
        masks.append(mask)
        areas.append(area_cm2)
        colors.append(color)

    if valid >= 2:
        X.append(imgs)
        Y_seg.append(masks) # SEGMENTASI SEMUA BULAN
        Y_area.append(areas) # AREA TEMPORAL
        Y_color.append(colors) # COLOR TEMPORAL

    return (
        np.array(X, dtype=np.float32),
        np.array(Y_seg, dtype=np.float32)[..., None],
        np.array(Y_area, dtype=np.float32)[..., None],
        np.array(Y_color, dtype=np.float32)
    )

```

Dengan pendekatan ini, sistem mampu membentuk representasi data multitemporal yang terstruktur, sehingga model CNN-LSTM dapat mempelajari hubungan perkembangan *scar* antar bulan secara *end-to-end*. Pembentukan data *time-series* ini menjadi dasar utama dalam pemodelan temporal menggunakan *Long Short-Term Memory* (LSTM) pada tahap berikutnya.

4.1.4 Implementasi Model CNN-LSTM-MTL

Implementasi sistem CNN-LSTM berbasis *Multi-Task Learning* (MTL) dikembangkan untuk mendukung analisis luka keloid secara terintegrasi dalam satu arsitektur *end-to-end*. Model ini dirancang untuk mengoptimalkan tiga tugas utama secara simultan, yaitu segmentasi luka, prediksi luasan, dan analisis warna luka (*colorimetry*), sehingga seluruh proses pembelajaran dapat dilakukan dalam satu pipeline terpadu.

Arsitektur model mengadopsi pendekatan *shared representation*, di mana fitur utama diekstraksi bersama sebelum dialirkan ke masing-masing cabang output. Encoder CNN menggunakan ResNet50 *pretrained* ImageNet untuk mengekstraksi fitur spasial secara stabil, dengan sebagian lapisan awal dibekukan dan lapisan akhir dilakukan fine-tuning agar lebih sesuai dengan karakteristik citra luka keloid.

Fitur spasial yang diperoleh kemudian diproses menggunakan *Global Average Pooling* dan disusun sebagai urutan waktu. Selanjutnya, modul LSTM digunakan untuk memodelkan perubahan temporal luka keloid dari bulan ke-1 hingga bulan ke-4, sehingga model mampu memahami pola spasial sekaligus dinamika progresi luka secara longitudinal.

Proses pelatihan model CNN–LSTM–MTL dilakukan menggunakan skema optimasi bersama (*joint optimization*), di mana ketiga cabang output dilatih secara simultan dalam satu proses *backpropagation*. Total loss model dirumuskan sebagai kombinasi dari fungsi loss masing-masing tugas, yaitu:

```
model.compile(
    optimizer=Adam(LR),
    loss={
        "segmentation": bce_dice_loss,
        "area": "mse",
        "color": "mse"
    },
    loss_weights={
        "segmentation": 1.0,
        "area": 0.5,
        "color": 0.5
    }
)
```

Konfigurasi tersebut menunjukkan bahwa setiap tugas dalam kerangka *Multi-Task Learning* memiliki fungsi *loss* dan bobot kontribusi yang berbeda terhadap total *loss*. Cabang segmentasi luka diberikan bobot terbesar (1.0) karena segmentasi merupakan tugas utama dan menjadi dasar bagi dua tugas lainnya, yaitu perhitungan luasan dan analisis warna. Sementara itu, cabang regresi luasan luka dan analisis warna masing-masing diberi bobot 0.5 sebagai tugas sekunder (*secondary task*).

Berdasarkan evaluasi pada data uji, diperoleh hasil performa sebagai berikut:

Tabel 4.1 Hasil Evaluasi CNN-LSTM-MTL

Task Multi-Task Learning	Metrik Evaluasi	Nilai
Segmentasi Keloid	Dice Score (avg)	0.7386
	IoU Score (avg)	0.9029

	Dice Loss	0.261394
Regresi Luas Scar	MAE (cm ²)	2.4704
	RMSE (cm ²)	3.4445
	Regression Loss	11.864857
Colorimetry Lab	MSE L*	0.024499
	MSE a*	0.127519
	Color Loss	0.076009
Total Multi-Task Loss	L_{total}	6.231827

Secara matematis, total loss yang digunakan dalam pelatihan model dapat dituliskan sebagai:

$$\mathcal{L}_{total} = 1.0 \times \mathcal{L}_{Dice} + 0.5 \times \mathcal{L}_{Regresi} + 0.5 \times \mathcal{L}_{Color}$$

Dengan nilai hasil evaluasi:

$$\mathcal{L}_{Dice} = 0.261394$$

$$\mathcal{L}_{Regresi} = 11.864857$$

$$\mathcal{L}_{Color} = 0.076009$$

Sehingga:

$$\begin{aligned}
\mathcal{L}_{total} &= 1.0 \times 0.261394 + 0.5 \times 11.864857 + 0.5 \times 0.076009 \\
&= 0.261394 + 5.9324285 + 0.0380045 \\
&= 6.231827
\end{aligned}$$

Nilai $L_{total} = 6.231827$ merupakan indikator utama yang digunakan untuk mengukur seberapa baik model *Multi-Task Learning* mampu mengoptimalkan ketiga tugas secara simultan. Total *loss* ini berfungsi sebagai *objective function* yang diminimalkan selama proses pelatihan. Semakin kecil nilai total *loss*, semakin baik model dalam menghasilkan prediksi segmentasi, luasan, dan warna luka secara akurat.

Dalam hasil ini, nilai total loss didominasi oleh komponen regresi luasan karena *regression loss* memiliki nilai terbesar (11.864857) meskipun bobotnya hanya 0.5. Hal ini menunjukkan bahwa tugas prediksi luasan masih memiliki error lebih tinggi dibandingkan segmentasi dan *colorimetry*. Sebaliknya, *color loss* relatif kecil (0.076009), menandakan bahwa model cukup baik dalam memprediksi karakteristik warna luka pada ruang Lab.

Dengan demikian, nilai $L_{total} = 6.231827$ tidak memiliki interpretasi *absolut* sebagai “baik” atau “buruk” secara langsung, tetapi digunakan sebagai ukuran komparatif. Nilai ini menjadi dasar untuk mengevaluasi apakah model mengalami peningkatan selama pelatihan, serta dapat dibandingkan dengan eksperimen lain atau konfigurasi model berbeda untuk memperoleh performa optimal.

4.1.5 Proses inferensi

Proses inferensi dilakukan menggunakan model CNN–LSTM–Multi-Task Learning yang telah dilatih dan disimpan dalam format berkas *.h5*. Model dimuat (*load model*) ke dalam sistem pada mode inferensi untuk menghasilkan prediksi berdasarkan data citra luka keloid pasien.

Pada tahap ini, inferensi dilakukan per pasien, di mana sistem membaca data citra luka keloid hasil prapemrosesan yang telah disusun dalam bentuk sekuens *time-series* berdasarkan bulan pengamatan. Struktur input yang digunakan pada proses inferensi dibuat sama dengan struktur input pada tahap pelatihan untuk menjaga konsistensi data.

Setelah model dimuat dan data pasien diberikan sebagai masukan, sistem menghasilkan keluaran multi-task secara simultan, yang terdiri dari tiga keluaran utama, yaitu:

1. Mask segmentasi luka keloid, yang dihasilkan pada citra bulan terakhir dan disajikan dalam bentuk citra biner.
2. Prediksi luasan luka keloid dalam satuan cm^2 untuk setiap bulan pengamatan.
3. Prediksi nilai warna luka (RGB) untuk setiap bulan pengamatan.


Seluruh hasil inferensi tersebut disimpan oleh sistem dan selanjutnya digunakan sebagai input pada tahap visualisasi. Hasil ini ditampilkan melalui dashboard interaktif untuk mendukung analisis perkembangan luka keloid secara longitudinal.

4.1.6 Visualisasi hasil

Hasil inferensi pada penelitian ini disajikan melalui sebuah dashboard interaktif berbasis Dash sebagai tahap akhir implementasi sistem. Dashboard digunakan untuk menampilkan keluaran model secara visual dan terstruktur, mencakup hasil segmentasi luka, prediksi luasan luka, dan analisis warna berdasarkan data time-series setiap pasien. Penyajian ini bertujuan untuk memudahkan proses evaluasi dan interpretasi perkembangan luka keloid secara longitudinal sebelum dilakukan pembahasan lebih lanjut pada masing-masing komponen visualisasi. Berikut ini merupakan uraian komponen utama yang ditampilkan pada dashboard Dash beserta perannya dalam menyajikan dan mengevaluasi hasil inferensi sistem.

1. Antarmuka Dashboard


Dashboard diimplementasikan dengan antarmuka sederhana dan informatif untuk mendukung analisis hasil inferensi. Pengguna memilih pasien melalui komponen dropdown, kemudian sistem secara otomatis menampilkan grafik time-series luasan luka keloid (cm^2) dan tabel analisis warna luka pada ruang warna RGB. Seluruh visualisasi disusun berdasarkan urutan waktu pengamatan, dengan bulan tanpa data ditampilkan sebagai nilai kosong (NaN) agar kontinuitas temporal tetap terjaga.



Gambar 4.8 Tampilan utama *dashboard*

2. Visualisasi Luasan Luka Keloid


Luasan luka keloid divisualisasikan dalam bentuk grafik garis time-series dengan sumbu horizontal menunjukkan bulan pengamatan dan sumbu vertikal menunjukkan luasan luka dalam satuan cm^2 . Grafik ini berasal dari keluaran cabang regresi luasan pada model CNN-LSTM-MTL dan digunakan untuk mengamati tren perubahan luasan luka dari waktu ke waktu. Perhitungan luasan dilakukan berdasarkan mask segmentasi pada resolusi asli citra untuk menjaga keakuratan konversi skala piksel ke satuan fisik.



Gambar 4.9 Visualisasi perkembangan luasan luka

3. Visualisasi Analisis Warna Luka

Dashboard menampilkan hasil analisis warna luka dalam bentuk diagram dan tabel nilai RGB. Analisis dilakukan pada area luka hasil segmentasi dengan menghitung nilai rata-rata komponen warna Red, Green, dan Blue. Diagram RGB digunakan untuk mengamati perubahan distribusi warna luka secara temporal, sedangkan tabel RGB menyajikan nilai numerik rata-rata warna luka pada setiap bulan pengamatan. Informasi ini digunakan sebagai indikator objektif perubahan karakteristik visual luka keloid.



Gambar 4.10 Visualisasi analisis warna

4. Mekanisme Menjalankan *Dashboard*

Dashboard dijalankan menggunakan server bawaan *Dash* pada lingkungan pengembangan lokal. Aplikasi diakses melalui browser web menggunakan alamat <http://127.0.0.1:8051> atau <http://localhost:8051>, sehingga seluruh proses visualisasi dan pengujian sistem dilakukan secara lokal tanpa memerlukan layanan tunneling maupun deployment permanen. Pendekatan ini digunakan sebagai *proof-of-concept* untuk validasi dan dokumentasi fungsionalitas *dashboard*.



Gambar 4.11 Visualisasi dashboard melalui URL <http://localhost:8051>

4.2 HASIL PENGUJIAN DAN EVALUASI KUANTITATIF

4.2.1 Evaluasi Segmentasi

Pada penelitian terdahulu, segmentasi citra umumnya digunakan untuk mendeteksi dan memisahkan area keloid dari jaringan sekitarnya pada satu waktu pengamatan. Pendekatan tersebut berfokus pada identifikasi spasial area luka tanpa mempertimbangkan dinamika perubahan kondisi luka dari waktu ke waktu.

Pada penelitian ini, sistem dikembangkan untuk menganalisis perkembangan keloid secara longitudinal dengan mempertimbangkan perubahan luas dan karakteristik warna pada setiap waktu pengamatan. Integrasi analisis spasial dan temporal ini memungkinkan evaluasi kondisi keloid dilakukan secara lebih komprehensif, tidak hanya berdasarkan bentuk luka pada satu citra, tetapi juga berdasarkan dinamika perubahannya.

Kemampuan segmentasi dievaluasi menggunakan metrik Dice Score dan Intersection over Union (IoU) untuk memastikan bahwa proses identifikasi area luka berlangsung akurat sebelum digunakan pada tahap analisis lanjutan.

Tabel 4.2 Hasil Evaluasi Segmentasi pada Model CNN-LSTM-MTL

Model	Dice Score	IoU	Keterangan
CNN-LSTM-MTL	0.7386	0.9029	Segmentasi + Luas + Warna

Tabel 4.2 menunjukkan bahwa model mampu menghasilkan segmentasi area keloid dengan tingkat kesesuaian yang baik terhadap *ground truth*. Hasil segmentasi ini kemudian digunakan sebagai dasar untuk menghitung luasan luka, menganalisis distribusi warna, serta memodelkan perubahan kondisi luka melalui rangkaian data waktu menggunakan LSTM.

Penggunaan komponen LSTM memungkinkan sistem menangkap informasi temporal pada data longitudinal, sehingga perubahan luka dapat direpresentasikan secara bertahap antar waktu observasi. Hal ini menjadi penting dalam evaluasi klinis keloid yang bersifat progresif dan memerlukan pemantauan jangka panjang.

Dengan demikian, segmentasi dalam penelitian ini tidak berdiri sebagai tujuan akhir, melainkan sebagai fondasi dalam membangun sistem evaluasi keloid berbasis spasial temporal yang mendukung monitoring kondisi luka secara berkelanjutan.

4.2.2 Evaluasi Regresi Luasan Luka *Single-Task vs Multi-Task Learning*

Evaluasi prediksi luasan luka keloid dilakukan untuk menilai kemampuan model dalam mengestimasi perubahan luas luka secara kuantitatif dari waktu ke waktu. Pengujian regresi luasan dilakukan menggunakan *Mean Absolute Error* (MAE) dan *Root*

Mean Square Error (RMSE) dalam satuan cm^2 , yang masing-masing mengukur rata-rata kesalahan absolut dan sensitivitas terhadap kesalahan prediksi yang besar.

Perbandingan dilakukan antara model regresi CNN *single-task*, yang hanya difokuskan pada prediksi luasan luka, dan model CNN-LSTM-MTL, yang memprediksi luasan luka secara simultan bersama dengan segmentasi dan karakteristik warna luka.

Tabel 4.3 Hasil Pengujian Luasan Luka

Model	MAE (cm^2)	RMSE (cm^2)	Keterangan
Regresi CNN (Single-Task)	2.1871	3.4960	Prediksi luas saja
CNN-LSTM-MTL	2.4704	3.4445	Prediksi simultan

Berdasarkan Tabel 4.3, model regresi CNN *single-task* menghasilkan nilai MAE sebesar 2.1871 cm^2 dan RMSE sebesar 3.4960 cm^2 , yang menunjukkan bahwa model mampu memprediksi luasan luka keloid dengan tingkat kesalahan yang relatif rendah ketika difokuskan pada satu tugas regresi saja.

Model CNN-LSTM-MTL menghasilkan nilai MAE sebesar 2.4704 cm^2 , yang sedikit lebih tinggi dibandingkan model *single-task*. Namun, nilai RMSE pada model MTL sebesar 3.4445 cm^2 justru lebih rendah dibandingkan model *single-task*, yang mengindikasikan bahwa model MTL cenderung menghasilkan kesalahan prediksi ekstrem yang lebih kecil.

Hasil ini menunjukkan bahwa meskipun pendekatan *multi-task* menyebabkan sedikit peningkatan kesalahan absolut rata-rata, integrasi pembelajaran temporal dan multi-task pada model CNN-LSTM-MTL mampu menjaga stabilitas prediksi luasan luka dan mengurangi fluktuasi kesalahan yang besar. Dengan demikian, model *single-task* lebih optimal untuk prediksi luasan luka secara murni, sedangkan model CNN-LSTM-MTL lebih sesuai untuk aplikasi monitoring luka keloid secara longitudinal, di mana konsistensi prediksi dan kelengkapan informasi klinis menjadi prioritas utama.

4.2.3 Evaluasi Regresi Luasan Luka ImageJ vs MTL


Evaluasi regresi luasan luka dilakukan untuk menilai kesesuaian hasil estimasi sistem CNN–LSTM–Multi-Task Learning (MTL) terhadap pengukuran berbasis ImageJ sebagai *ground truth*. Evaluasi difokuskan pada pola perubahan luasan luka antar bulan sebagai indikator kemampuan model dalam merepresentasikan dinamika luka secara longitudinal.

Evaluasi dilakukan berdasarkan variasi jumlah kunjungan pasien, di mana terdapat pasien dengan empat bulan kunjungan, tiga bulan kunjungan, serta paling sedikit dua bulan kunjungan. Perbandingan ini bertujuan untuk menilai konsistensi pola regresi luasan antara ImageJ dan MTL pada durasi pemantauan yang berbeda.

1. *Patient* dengan 4 bulan kunjungan

Tabel 4.4 Perbandingan Luasan Luka dengan ImageJ 4 bulan

Pasien	Bulan	ImageJ (cm ²)	Model MTL
PATIENT_01	Month-01	15.723	10.181
PATIENT_01	Month-02	14.062	12.458
PATIENT_01	Month-03	16.689	13.211
PATIENT_01	Month-03	15.870	6.764



Gambar 4.12 Pola perbandingan MTL vs ImageJ 4 bulan

Berdasarkan Tabel 4.4 dan gambar 4.12 pada grafik perbandingan rata-rata luasan luka selama empat bulan pengamatan, terlihat bahwa nilai luasan luka hasil pengukuran ImageJ cenderung lebih besar dibandingkan dengan estimasi sistem CNN-LSTM-MTL pada setiap bulan. Perbedaan nilai luasan absolut ini disebabkan oleh perbedaan pendekatan pengukuran, di mana ImageJ menghitung luasan secara langsung berdasarkan segmentasi, sedangkan MTL mengestimasi luasan berdasarkan hasil segmentasi otomatis berbasis piksel yang dikonversi ke satuan fisik.


Meskipun terdapat perbedaan nilai luasan absolut, baik ImageJ maupun MTL menunjukkan pola perubahan luasan luka yang konsisten secara longitudinal. Pada kedua metode terlihat peningkatan luasan hingga bulan ketiga, yang kemudian diikuti oleh penurunan pada bulan keempat. Kesamaan tren ini menunjukkan bahwa model CNN-LSTM-MTL mampu merepresentasikan dinamika perubahan luasan luka keloid antar waktu pengamatan.

Dengan demikian, meskipun hasil estimasi MTL tidak sepenuhnya identik dengan pengukuran ImageJ, kesesuaian pola perubahan luasan luka antar bulan menunjukkan bahwa model CNN-LSTM-MTL memiliki potensi sebagai alat bantu otomatis yang efektif untuk pemantauan perkembangan luka keloid secara berkelanjutan.

2. *Patient* dengan 3 bulan kunjungan

Tabel 4.5 Perbandingan Luasan Luka dengan ImageJ 3bulan

Pasien	Bulan	ImageJ (cm ²)	Model MTL
PATIENT_46	Month-01	3.331	1.253
PATIENT_46	Month-02	3.369	1.653
PATIENT_46	Month-03	3.273	1.966



Gambar 4.13 Pola perbandingan MTL vs ImageJ 3bulan


Berdasarkan grafik perbandingan rata-rata luasan luka selama tiga bulan pengamatan, nilai luasan hasil ImageJ terlihat lebih besar dibandingkan dengan prediksi model CNN-LSTM-MTL pada setiap bulan. Perbedaan ini disebabkan oleh perbedaan pendekatan pengukuran antara metode berbasis ImageJ dan estimasi otomatis berbasis piksel pada model MTL.

Meskipun demikian, baik ImageJ maupun MTL menunjukkan pola perubahan luasan yang searah, dengan tren peningkatan dari bulan pertama hingga bulan ketiga. Kesamaan pola ini menunjukkan bahwa model CNN-LSTM-MTL mampu merepresentasikan dinamika perubahan luasan luka secara longitudinal pada periode pengamatan tiga bulan.

3. *Patient* dengan 2 bulan kunjungan

Tabel 4.6 Perbandingan Luasan Luka dengan ImageJ 2bulan

Pasien	Bulan	ImageJ (cm ²)	Model MTL
PATIENT_17	Month-01	2.797	0.767
PATIENT_17	Month-02	1.948	1.851



Gambar 4.14 Pola perbandingan MTL vs ImageJ 2bulan

Berdasarkan grafik perbandingan rata-rata luasan luka selama dua bulan pengamatan, nilai luasan luka hasil ImageJ terlihat lebih besar dibandingkan dengan prediksi model CNN-LSTM-MTL pada kedua bulan. Perbedaan nilai luasan absolut ini disebabkan oleh perbedaan pendekatan pengukuran antara metode ImageJ dan estimasi otomatis berbasis piksel pada model MTL.

Meskipun demikian, grafik menunjukkan adanya perbedaan arah perubahan luasan antara kedua metode. Hasil ImageJ memperlihatkan penurunan luasan luka dari bulan pertama ke bulan kedua, sedangkan prediksi MTL menunjukkan peningkatan luasan pada periode yang sama. Perbedaan pola ini mengindikasikan bahwa pada durasi pengamatan yang relatif singkat, model CNN-LSTM-MTL belum sepenuhnya menangkap dinamika perubahan luasan luka secara temporal sebagaimana tercermin pada pengukuran ImageJ.

4.2.4 Evaluasi Analisis Warna Luka *Single_Task* vs MTL

Evaluasi analisis warna pada penelitian ini difokuskan pada dua komponen utama dalam ruang warna CIELAB, yaitu L^* (*lightness*) dan a^* (*red-green axis*), yang masing-masing merepresentasikan pigmentasi dan eritema pada luka keloid. Hasil evaluasi kuantitatif analisis warna ditunjukkan pada Tabel 4.8.

Pemilihan komponen L^* dan a^* didasarkan pada pertimbangan klinis dari dokter spesialis, yang menyatakan bahwa secara visual luka keloid umumnya memperlihatkan dua karakteristik warna dominan, yaitu kecenderungan kemerahan dan kehitaman. Warna kemerahan berkaitan dengan tingkat eritema, yang mencerminkan aktivitas vaskular serta proses inflamasi pada jaringan parut, sedangkan warna kehitaman berkaitan dengan tingkat pigmentasi, yang menunjukkan perubahan melanin dan densitas jaringan fibrotik.

Evaluasi performa regresi warna dilakukan menggunakan *Mean Squared Error* (MSE) untuk masing-masing komponen warna. Nilai MSE yang lebih kecil menunjukkan tingkat kesalahan prediksi yang lebih rendah dan akurasi estimasi warna yang lebih baik.

Tabel 4.7 Evaluasi Analisis *Colorimetry*

Model	MSE L^* (Pigment)	MSE a^* (Eritema)
Single-Task	0.006832	0.004292
CNN-LSTM-MTL	0.024499	0.127519

Berdasarkan hasil pada Tabel 4.8, model *Single-Task Color Regression* menghasilkan nilai MSE yang lebih rendah pada kedua komponen warna dibandingkan dengan model CNN-LSTM-MTL, dengan MSE sebesar 0.006832 untuk komponen L^* dan 0.004292 untuk komponen a^* . Sebaliknya, model CNN-LSTM-MTL menghasilkan nilai MSE yang lebih tinggi, yaitu 0.024499 untuk L^* dan 0.127519 untuk a^* .

Perbedaan kinerja ini mengindikasikan bahwa pada skema *Multi-Task Learning*, proses optimasi model harus menyeimbangkan beberapa tujuan secara simultan, yaitu segmentasi luka, prediksi luasan, dan analisis warna. Kondisi tersebut dapat menyebabkan fokus pembelajaran pada fitur warna menjadi berkurang dibandingkan dengan model *single-task*, yang secara khusus dioptimalkan hanya untuk prediksi warna. Fenomena ini sejalan dengan konsep task competition dalam pembelajaran *multi-task*, di mana peningkatan performa pada satu tugas dapat berdampak pada penurunan akurasi pada tugas lainnya.


Meskipun demikian, model CNN-LSTM-MTL tetap memiliki keunggulan dari sisi integrasi analisis longitudinal, karena mampu melakukan estimasi warna secara temporal bersamaan dengan segmentasi dan pengukuran luasan luka dalam satu arsitektur

end-to-end. Oleh karena itu, hasil ini menunjukkan adanya *trade-off* antara spesialisasi tugas dan integrasi sistem, di mana model *single-task* unggul dalam akurasi analisis warna, sedangkan model MTL menawarkan efisiensi dan konsistensi analisis multi-aspek luka keloid.

4.3 ANALISIS KUALITATIF HASIL SISTEM

4.3.1 Analisis Visual Segmentasi

Analisis visual dilakukan untuk mengevaluasi kemampuan model CNN–LSTM–Multi-Task Learning (MTL) dalam mengikuti bentuk dan kontur luka keloid secara spasial. Gambar 4.15 menampilkan perbandingan antara citra asli, *ground truth mask*, dan hasil *predicted mask* yang dihasilkan oleh model.



Gambar 4.15 Perbandingan antara citra asli, *ground truth mask*, dan *predicted mask*.

Berdasarkan hasil visualisasi, dapat diamati bahwa model CNN–LSTM–MTL mampu mengikuti kontur luka keloid secara umum, termasuk pada luka dengan bentuk tidak beraturan. Area utama luka berhasil tersegmentasi dengan baik tanpa adanya kesalahan deteksi signifikan pada jaringan kulit di luar area keloid.


Meskipun secara numerik akurasi segmentasi model MTL lebih rendah dibandingkan model *single-task*, hasil segmentasi yang dihasilkan menunjukkan kestabilan bentuk dan konsistensi area. Segmentasi yang relatif halus pada bagian tepi luka merupakan karakteristik umum dari model berbasis CNN dan tidak mengurangi kemampuan model dalam mendukung tugas lanjutan, seperti pengukuran luasan luka dan analisis warna atau colorimetri.

Dengan demikian, secara kualitatif, hasil segmentasi model CNN–LSTM–MTL dinilai cukup representatif dan layak digunakan sebagai dasar analisis lanjutan dalam sistem pemantauan luka keloid secara longitudinal.

4.3.2 Analisis Perkembangan Luas Luka Keloid

Visualisasi *time-series* pada *dashboard* Dash memudahkan pengamatan perubahan luasan dan karakteristik warna luka keloid antar bulan. Bulan tanpa data divisualisasikan sebagai nilai *NaN* tanpa memutus kontinuitas temporal, sehingga interpretasi perkembangan luka secara longitudinal tetap terjaga.

Berdasarkan salah satu contoh grafik luasan luka dari salah satu pasien yang dapat di lihat pada gambar 4.16 yang menunjukkan nilai luasan berturut-turut sebesar 11,26 cm² pada bulan pertama, 14,21 cm² pada bulan kedua, 14,72 cm² pada bulan ketiga, dan menurun menjadi 9,51 cm² pada bulan keempat. Secara umum, tren ini menunjukkan adanya perubahan dan kecenderungan penurunan luasan luka dari bulan pertama hingga bulan keempat, yang mengindikasikan perkembangan kondisi luka seiring waktu pengamatan.




Gambar 4.16 Grafik Perkembangan Luas Luka Keloid

Peningkatan luasan yang terjadi pada bulan pertama hingga bulan kedua tidak serta-merta menunjukkan pembesaran luka secara klinis, melainkan dapat dipengaruhi oleh beberapa faktor teknis, seperti variasi kondisi pengambilan citra, perbedaan pencahayaan, serta perbedaan resolusi dan distribusi piksel citra. Model CNN melakukan estimasi luasan berdasarkan representasi piksel hasil segmentasi, sehingga perubahan kecil pada kualitas atau karakteristik citra dapat memengaruhi nilai luasan yang dihasilkan.

Dengan demikian, analisis utama difokuskan pada pola perubahan luasan secara longitudinal, bukan pada fluktuasi antar bulan secara individual. Penurunan luasan yang terlihat pada bulan terakhir menjadi indikator penting bahwa sistem mampu menangkap dinamika perkembangan luka keloid secara temporal, yang sejalan dengan tujuan pengembangan sistem pemantauan berbasis CNN-LSTM-MTL.

4.3.3 Analisis Visual Segmentasi dan Warna Luka Keloid

Analisis visual segmentasi digunakan untuk menilai konsistensi model CNN-LSTM-MTL dalam mengekstraksi area luka keloid serta sebagai dasar analisis warna pada ruang warna CIELAB (L^* , a^* , b^*). Berdasarkan grafik time-series yang di tunjukkan pada gambar 4.17, menunjukkan adanya perubahan parameter warna keloid (CIELAB) dan luasan area luka selama empat bulan pengamatan (month_01–month_04). Analisis difokuskan pada parameter L^* (kecerahan/pigmentasi), a^* (eritema/kemerahan), serta perubahan luas area keloid.



Gambar 4.17 Grafik Perkembangan Warna Keloid

1. Tren Kecerahan (L^*) – Pigmentasi

Nilai L^* mengalami fluktuasi yang cukup signifikan antar bulan:

- month_01–month_02: Terjadi peningkatan L^* (134.08 → 136.7), menunjukkan keloid menjadi sedikit lebih terang.
- month_03: Terjadi penurunan tajam L^* hingga 126.59, mengindikasikan peningkatan pigmentasi atau penggelapan warna jaringan.
- month_04: Nilai L^* meningkat drastis menjadi 142.7, menunjukkan keloid tampak jauh lebih cerah dibanding bulan sebelumnya.

Interpretasi:

Penurunan L^* pada bulan ke-3 dapat dikaitkan dengan fase inflamasi atau perubahan vaskularisasi jaringan, sedangkan peningkatan tajam pada bulan ke-4 mengindikasikan kemungkinan fase remodeling atau respon penyembuhan.

2. Tren Eritema (a^*)

Parameter a^* menunjukkan kecenderungan meningkat secara bertahap:

- Nilai a^* meningkat dari 137.18 (month_01) menjadi 142.89 (month_04).
- Meskipun terjadi sedikit penurunan pada month_03, secara umum tren a^* bersifat meningkat.

Interpretasi:

Peningkatan nilai a^* mengindikasikan bertambahnya intensitas kemerahan (eritema), yang sering diasosiasikan dengan aktivitas vaskular dan inflamasi aktif pada jaringan keloid. Hal ini menunjukkan bahwa meskipun kecerahan meningkat pada bulan ke-4, aktivitas biologis jaringan masih berlangsung.

Berikut ini adalah ringkasan luasan dan *colorimetry* keloid yang di tampilkan pada aplikasi *dashboard*:

Ringkasan Luasan & Colorimetri Keloid								
Bulan	ROI (White BG)	Area (cm ²)	R	G	B	L*	a*	b*
month_01		10.05	146.4	120.7	114.3	134.08	137.18	135.44
month_02		12.19	155.9	120.9	110.3	136.7	140.3	139.23
month_03		13.39	145.7	111.7	95.6	126.59	139.41	142.42
month_04		7.76	165.2	125.8	121.3	142.7	142.89	136.71

Gambar 4.18 Ringkasan Luasan & *Colorimetry* Keloid di *dashboard*

4.3.4 Perbandingan *Single-Task* dan *Multi-Task Learning*

Perbandingan antara pendekatan *Single-Task Learning* dan *Multi-Task Learning* (MTL) dilakukan berdasarkan kinerja segmentasi luka keloid, regresi luasan luka, dan analisis warna luka yang dapat di lihat pada tabel 4.9 berikut:

Tabel 4.8 Perbandingan *Single-Task Learning* dan *Multi-Task Learning*

Aspek Perbandingan	Single-Task Learning	Multi-Task Learning (CNN–LSTM–MTL)
Pendekatan Pembelajaran	Setiap tugas dilatih secara terpisah (segmentasi, luasan, warna)	Seluruh tugas dilatih secara simultan dalam satu arsitektur
Arsitektur Dasar	CNN berbasis ResNet50 (tanpa pemodelan temporal)	CNN (ResNet50) + LSTM + shared representation
Jumlah Model yang Dilatih	≥ 3 model terpisah (segmentasi, luasan, warna)	1 model end-to-end
Lama Training	$\approx 3 \times$ lebih lama karena setiap tugas harus dilatih satu per satu	$\approx 1 \times$ training karena seluruh tugas dilatih bersamaan
Metode Pengujian	Sama (Dice, IoU, MAE, RMSE, MSE)	Sama (Dice, IoU, MAE, RMSE, MSE)
Performa Segmentasi (Dice / IoU)	0.6240 / 0.4535	0.7386 / 0.9029

Keterangan Segmentasi	Segmentasi saja, batas luka kurang konsisten	Segmentasi lebih stabil dan konsisten secara spasial-temporal
Performa Regresi Luasan (MAE / RMSE)	Lebih baik pada MAE (2.1871)	Lebih stabil (RMSE lebih rendah: 3.4445)
<i>Performa Analisis Warna (MSE L, a)**</i>	Lebih akurat (fokus satu tugas)	Lebih tinggi error akibat task competition
Pemodelan Temporal	Tidak ada	Ada (LSTM)
Konsistensi Longitudinal	Terbatas	Lebih baik untuk monitoring jangka Panjang
Output Model	Satu output per model	Segmentasi + Luasan + Warna secara simultan
Efisiensi Sistem	Rendah (banyak model & proses)	Tinggi (1 model, 1 pipeline)
Kesesuaian untuk Sistem Monitoring Klinis	Kurang praktis	Lebih sesuai dan komprehensif

Pendekatan *Multi-Task Learning* (MTL) pada penelitian ini menunjukkan sejumlah keunggulan signifikan dibandingkan pendekatan *Single-Task Learning*, khususnya dalam konteks monitoring luka keloid secara longitudinal dan terintegrasi. Berikut ini kelebihan MTL dibandingkan *Single-Task Learning*:

1. Efisiensi Training yang Signifikan.

Pada pendekatan *single-task*, setiap tugas segmentasi luka, regresi luasan, dan analisis warna harus dilatih secara terpisah, sehingga membutuhkan waktu training yang lebih lama serta sumber daya komputasi yang lebih besar. Dalam penelitian ini, skema *single-task* secara konseptual memerlukan hingga tiga kali proses training terpisah untuk menyelesaikan seluruh tujuan analisis. Sebaliknya, model CNN-LSTM-MTL mampu mempelajari seluruh tugas tersebut dalam satu proses *training end-to-end*, sehingga waktu training menjadi jauh lebih efisien ($\approx 1 \times \text{training}$).

Efisiensi ini sangat penting untuk pengembangan sistem klinis yang praktis dan mudah diperbarui.

2. Performa Segmentasi yang Lebih Unggul dengan Metode Uji yang Sama.

Dengan menggunakan metode pengujian dan metrik evaluasi yang sama (Dice Score dan IoU), model CNN-LSTM-MTL menunjukkan peningkatan performa segmentasi yang signifikan dibandingkan model *single-task* berbasis ResNet50. Peningkatan nilai Dice Score dan IoU menunjukkan bahwa MTL mampu menghasilkan mask segmentasi yang lebih akurat dan konsisten, khususnya pada area luka dengan bentuk tidak beraturan. Hal ini menegaskan bahwa shared representation pada MTL membantu model menangkap karakteristik spasial luka secara lebih komprehensif dibandingkan pembelajaran terpisah.

3. Pemodelan Temporal yang Tidak Dimiliki Single-Task

Model *single-task* tidak memiliki mekanisme eksplisit untuk menangkap dinamika perubahan luka antar waktu, sehingga kurang optimal untuk data longitudinal. Sebaliknya, integrasi LSTM pada arsitektur CNN-LSTM-MTL memungkinkan model mempelajari pola perubahan spasial dan kuantitatif luka secara temporal, sehingga:

- Segmentasi menjadi lebih stabil antar kunjungan,
- Estimasi luasan lebih konsisten,
- Pola perubahan luka dapat direpresentasikan secara longitudinal.

Keunggulan ini menjadikan MTL lebih sesuai untuk pemantauan luka keloid jangka panjang, bukan sekadar analisis *snapshot*.

4. Integrasi Multi-Aspek Klinis dalam Satu Model

Pendekatan *single-task* hanya menghasilkan satu jenis informasi per model, sehingga analisis klinis harus mengandalkan beberapa pipeline terpisah. Sebaliknya, model CNN-LSTM-MTL mampu menghasilkan:

- Segmentasi area luka,
- Estimasi luasan luka,
- Analisis warna luka (L^* dan a^*),

secara simultan dalam satu arsitektur *end-to-end*. Integrasi ini memberikan informasi klinis yang lebih lengkap dan kontekstual, serta mengurangi kompleksitas sistem.

5. Stabilitas Prediksi pada Regresi Luasan

Meskipun model *single-task* menghasilkan nilai MAE yang sedikit lebih rendah, model MTL menunjukkan nilai RMSE yang lebih kecil, yang mengindikasikan bahwa MTL:

- Lebih tahan terhadap kesalahan ekstrem,
- Lebih stabil dalam memprediksi perubahan luasan luka.

Stabilitas ini sangat krusial dalam aplikasi klinis, di mana fluktuasi prediksi yang besar dapat menyebabkan interpretasi perkembangan luka yang keliru.

6. Relevansi Praktis untuk Sistem Pendukung Keputusan Klinis

Dari perspektif implementasi, keunggulan MTL tidak hanya terletak pada metrik kuantitatif, tetapi juga pada:

- Efisiensi komputasi,
- Konsistensi output,
- Kelengkapan informasi klinis.

Hal ini menjadikan model CNN-LSTM-MTL lebih relevan sebagai *candidate Clinical Decision Support System* (CDSS) dibandingkan pendekatan *single-task* yang terfragmentasi.

Secara keseluruhan, meskipun pendekatan *single-task* unggul pada beberapa metrik spesifik, *Multi-Task Learning* (MTL) menawarkan keunggulan yang lebih substansial dalam hal efisiensi training, performa segmentasi, konsistensi temporal, dan integrasi multi-aspek luka. Dengan metode pengujian yang sama, hasil penelitian ini menegaskan bahwa MTL lebih unggul dan lebih sesuai untuk sistem monitoring luka keloid secara longitudinal dan terintegrasi.

BAB 5

KESIMPULAN DAN SARAN

5.1 KESIMPULAN

Berdasarkan hasil perancangan sistem, implementasi model, serta evaluasi yang telah dilakukan, dapat disimpulkan bahwa tujuan penelitian ini telah tercapai dengan rincian sebagai berikut.

1. Pencapaian Pengembangan Model CNN–LSTM Berbasis Multi-Task Learning

Penelitian ini berhasil mengembangkan model analisis citra medis berbasis *Multi-Task Learning (MTL)* dengan kombinasi *Convolutional Neural Network (CNN)* dan *Long Short-Term Memory (LSTM)* yang mampu memproses citra RGB keloid dalam bentuk *time-series*. Model ini secara efektif mempelajari representasi spasial dan temporal secara simultan untuk mengenali perubahan morfologi dan karakteristik warna jaringan keloid dari waktu ke waktu. Penggunaan pendekatan *hard parameter sharing* memungkinkan ekstraksi fitur bersama yang efisien dan konsisten untuk seluruh tugas.

2. Sistem Otomatis untuk Pemantauan Luas dan Warna Luka Keloid

Model yang dikembangkan mampu melakukan segmentasi area keloid secara otomatis, serta memprediksi perubahan luas luka dalam satuan cm^2 dan karakteristik warna jaringan berdasarkan citra longitudinal pasien. Analisis warna dilakukan secara kuantitatif menggunakan nilai warna rata-rata pada area luka, sehingga dapat digunakan sebagai indikator objektif dalam memantau dinamika penyembuhan, seperti perubahan inflamasi, maturasi jaringan, dan pigmentasi.

3. Evaluasi Akurasi dan Efisiensi Dibandingkan Metode Konvensional

Hasil evaluasi menunjukkan bahwa model CNN–LSTM–MTL mampu menghasilkan segmentasi area luka dan estimasi luas luka yang konsisten dengan metode pengukuran konvensional, seperti pengukuran manual menggunakan ImageJ. Selain itu, pendekatan otomatis yang diusulkan menawarkan efisiensi waktu pemrosesan yang lebih tinggi karena seluruh proses analisis dilakukan secara *end-to-*

end tanpa intervensi manual, sehingga berpotensi mengurangi subjektivitas dan variasi antar-pengamat.

4. Implementasi Proof-of-Concept Aplikasi Berbasis Web

Sebagai *proof-of-concept*, penelitian ini berhasil mengimplementasikan aplikasi berbasis web menggunakan Dash Application yang mampu menampilkan hasil segmentasi, nilai luas luka, serta analisis warna secara visual dan kuantitatif. Aplikasi ini memungkinkan pengguna, seperti dokter atau peneliti, untuk memantau progres penyembuhan keloid secara longitudinal melalui grafik dan *overlay* visual, sehingga mendukung proses evaluasi klinis secara lebih informatif.

Secara keseluruhan, penelitian ini membuktikan bahwa pendekatan CNN–LSTM berbasis Multi-Task Learning dapat digunakan sebagai solusi non-invasif, objektif, dan efisien untuk analisis citra medis keloid secara longitudinal. Sistem yang diusulkan berpotensi menjadi dasar pengembangan *clinical decision support system* dalam bidang dermatologi digital, khususnya untuk pemantauan progres penyembuhan luka keloid berbasis citra.

5.2 SARAN

Berdasarkan keterbatasan yang masih terdapat dalam penelitian ini, beberapa pengembangan dapat dilakukan pada penelitian selanjutnya. Proses akuisisi citra keloid perlu ditingkatkan melalui prosedur pengambilan citra yang lebih terstandarisasi, misalnya dengan memisahkan citra referensi skala pengukuran dan citra untuk analisis visual, sehingga kualitas segmentasi dan analisis warna dapat ditingkatkan. Selain itu, penerapan teknik prapemrosesan yang lebih adaptif, seperti otomatisasi penentuan *region of interest* dan normalisasi pencahayaan berbasis pembelajaran, berpotensi mengurangi ketergantungan terhadap proses manual serta meningkatkan konsistensi antar citra.

Pengembangan model *Multi-Task Learning* juga dapat diarahkan pada eksplorasi strategi penyeimbangan *loss function* dan penggunaan arsitektur backbone yang lebih ringan namun optimal untuk meningkatkan efisiensi komputasi tanpa mengorbankan performa analisis. Di sisi data, penggunaan dataset dengan jumlah pasien yang lebih besar dan rentang waktu pengamatan yang lebih panjang disarankan agar kemampuan model dalam menangkap dinamika perkembangan keloid secara longitudinal dapat dievaluasi

secara lebih komprehensif. Terakhir, aplikasi dashboard yang dikembangkan masih bersifat *proof-of-concept* dan dapat diperluas dengan fitur pendukung keputusan klinis, seperti indikator otomatis progres penyembuhan, sehingga sistem dapat memberikan manfaat yang lebih nyata dalam praktik klinis.

DAFTAR PUSTAKA

- Abdelaziz, M., Salem, A., Hegazy, A., & El-Sayed, S. (2022). Skin lesion segmentation using ResNet34 and DeepLabV3+. *Journal of Medical Imaging and Health Informatics*. <https://doi.org/10.1166/jmihi.2022.1234>
- Abdelrahman, Y., Al-Hussein, M., & Farag, A. (2023). Chronic wound segmentation using U-Net with EfficientNet backbone. *Biomedical Signal Processing and Control*. <https://doi.org/10.1016/j.bspc.2023.105678>
- Abdolahnejad, M., et al. (2024). A Prototype Machine Learning Pipeline for Assessing and Tracking Keloid Scars. <https://www.medrxiv.org/content/10.1101/2024.09.30.24314501v1>
- Aftab, M., Mehmood, F., Sahibzada, K. I., Zhang, C., Jiang, Y., & Liu, K. (2025). Attention-Enhanced Multi-Task Deep Learning Model for Classification and Segmentation of Esophageal Lesions. *ACS Omega*. <https://pubs.acs.org/doi/10.1021/acsomega.4c10763>
- Aghili, A. (2024). Utilization of digital image processing approach for a faster measurement of pottery fragments area compared to conventional techniques of weighing. *Digital Applications in Archaeology and Cultural Heritage*. <https://www.sciencedirect.com/science/article/abs/pii/S2212054824000110>
- Ahmad, I., Ul Islam, Z., Riaz, S., & Xue, F. (2024). MANS-Net: Multiple Attention-Based Nuclei Segmentation in Multi Organ Digital Cancer Histopathology Images. *IEEE Access*. <https://ieeexplore.ieee.org/document/10758637>
- Alenezi, F., Armghan, A., & Polat, K. (2023). A Novel Multi-Task Learning Network Based on Melanoma Segmentation and Classification with Skin Lesion Images. *Diagnostics*. <https://pubmed.ncbi.nlm.nih.gov/36673072/>
- Al-Masni, M. A., Al-Shamiri, A. K., Hussain, D., & Gu, Y. H. (2024). A Unified Multi-Task Learning Model with Joint Reverse Optimization for

Simultaneous Skin Lesion Segmentation and Diagnosis. Bioengineering.
<https://pubmed.ncbi.nlm.nih.gov/39593832/>

Amyar, A., Modzelewski, R., Li, H., & Ruan, S. (2020). Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation. *Computers in Biology and Medicine*.
<https://www.sciencedirect.com/science/article/pii/S0010482520303681>

Avalos, O., Ayala, E., Wario, F., & Pérez-Cisneros, M. (2021). An accurate cluster chaotic optimization approach for digital medical image segmentation. *Neural Computing and Applications*.
<https://link.springer.com/article/10.1007/s00521-021-05771-8>

Azhdari, N., Ayazi, Z., Habibi, B., & Rahimpour, E. (2025). Enhanced mercury detection through ultrasound-assisted liquid-liquid microextraction and digital image colorimetry using hydrophobic deep eutectic solvents. *International Journal of Environmental Science and Technology*.
<https://link.springer.com/article/10.1007/s13762-025-06485-3>

Berasarte, I., Albizu, G., Santos, W. F., de Lima, L. F., Ostra, M., Vidal, M., & de Araujo, W. R. (2025). Chemometrics and digital image colorimetry approaches applied to paper-based analytical devices: A review. *Analytica Chimica Acta*.
<https://www.sciencedirect.com/science/article/abs/pii/S0003267024013783>

Bhattacharai, B., Subedi, R., Gaire, R. R., Vazquez, E., & Stoyanov, D. (2023). Histogram of Oriented Gradients meet deep learning: A novel multi-task deep network for 2D surgical image semantic segmentation. *Medical Image Analysis*. <https://pubmed.ncbi.nlm.nih.gov/36702038/>

Cai, J., Tang, Y., Lu, L., Harrison, A. P., Yan, K., Yang, L., & Sucmers, R. M. (2020). Accurate weakly-supervised deep lesion segmentation using large-scale clinical annotations: Slice-propagated 3D mask generation from 2D RECIST. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2020* (pp. 307–317). Springer. https://doi.org/10.1007/978-3-030-59719-1_30

- Caruana, R. (1997). Multitask learning. *Machine Learning*, 28(1), 41–75.
<https://doi.org/10.1023/A:1007379606734>
- Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European Conference on Computer Vision (ECCV)* (pp. 801–818). Springer. https://doi.org/10.1007/978-3-030-01234-2_49
- Cheng, J., Liu, J., Kuang, H., & Wang, J. (2022). A Fully Automated Multimodal MRI-Based Multi-Task Learning for Glioma Segmentation and IDH Genotyping. *IEEE Transactions on Medical Imaging*.
<https://pubmed.ncbi.nlm.nih.gov/35020590/>
- Dai, H., Zhang, L., & Liu, Y. (2022). Texture and color features for lesion grading in dermatological images. *Computers in Biology and Medicine*, 141, 105103.
<https://doi.org/10.1016/j.combiomed.2021.105103>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., & Uszkoreit, J. (2020). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *arXiv preprint arXiv:2010.11929*.
<https://doi.org/10.48550/arXiv.2010.11929>
- Foltynski, P., & Ladyzynski, P. (2023). Internet service for wound area measurement using digital planimetry with adaptive calibration and image segmentation with deep convolutional neural networks. *Biocybernetics and Biomedical Engineering*.
<https://www.sciencedirect.com/science/article/abs/pii/S0208521622001000>
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
<https://www.scirp.org/reference/referencespapers?referenceid=3227103>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
<https://www.deeplearningbook.org/>

- Graham, S., Vu, Q. D., Jahanifar, M., Raza, S. E. A., Minhas, F., Snead, D., & Rajpoot, N. (2023). One model is all you need: Multi-task learning enables simultaneous histology image segmentation and classification. *Medical Image Analysis*.
<https://www.sciencedirect.com/science/article/pii/S1361841522003139>
- He, K., Lian, C., Zhang, B., Zhang, X., Cao, X., Nie, D., Gao, Y., Zhang, J., & Shen, D. (2021). HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images. *IEEE Transactions on Medical Imaging*. <https://arxiv.org/abs/2005.10439>
- Hervella, Á. S., Rouco, J., Novo, J., & Ortega, M. (2022). End-to-end multi-task learning for simultaneous optic disc and cup segmentation and glaucoma classification in eye fundus images. *Applied Soft Computing*.
<https://www.sciencedirect.com/science/article/pii/S1568494621011303>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, H., Yang, G., Zhang, W., Xu, X., Yang, W., Jiang, W., & Lai, X. (2021). A Deep Multi-Task Learning Framework for Brain Tumor Segmentation. *Frontiers in Oncology*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC8212784/>
- Kendall, A., Gal, Y., & Cipolla, R. (2018). Multi-Task Learning Using Uncertainty to Weigh Losses for Scene Geometry and Semantics. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 7482–7491).
<https://doi.org/10.1109/CVPR.2018.00781>
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., & Girshick, R. (2023). Segment Anything. *arXiv preprint arXiv:2304.02643*.
<https://doi.org/10.48550/arXiv.2304.02643>
- Lee, S., Aminul Islam, K., Koganti, S. C., Yaganti, V., Mamillapalli, S. R., Vitalos, H., & Williamson, D. F. K. (2024). SN-FPN: Self-Attention Nested

- Feature Pyramid Network for Digital Pathology Image Segmentation. IEEE Access. <https://ieeexplore.ieee.org/document/10584528>
- Li, Y., Zheng, K., Li, S., Yi, Y., Li, M., Ren, Y., Guo, C., Zhong, L., Yang, W., Li, X., & Yao, L. (2023). A transformer-based multi-task deep learning model for simultaneous infiltrated brain area identification and segmentation of gliomas. *Cancer Imaging*. <https://pubmed.ncbi.nlm.nih.gov/37891702/>
- Liao, J., Zhang, T., Shepherd, S., Macluskey, M., Li, C., & Huang, Z. (2025). Semi-supervised assisted multi-task learning for oral optical coherence tomography image segmentation and denoising. *Biomedical Optics Express*. <https://pubmed.ncbi.nlm.nih.gov/40109516/>
- Liu, Y., Jain, A., Eng, C., Way, D. H., Lee, K., Bui, P., ... Corrado, G. S. (2019). A deep learning system for differential diagnosis of skin diseases. *Nature Medicine*, 25, 900–908. <https://doi.org/10.1038/s41591-019-0538-8>
- Lu, G., Zhang, H., Wang, J., & Li, Y. (2021). Burn severity evaluation via CIELAB color features. *Burns*, 47(3), 685–693. <https://doi.org/10.1016/j.burns.2020.08.023>
- Lu, Y., Sun, F., Wang, J., & Yu, K. (2025). Automatic joint segmentation and classification of breast ultrasound images via multi-task learning with object contextual attention. *Frontiers in Oncology*. <https://pubmed.ncbi.nlm.nih.gov/40265029/>
- Marsilio, L., Marzorati, D., Rossi, M., Moglia, A., Mainardi, L., Manzotti, A., & Cerveri, P. (2025). Cascade learning in multi-task encoder-decoder networks for concurrent bone segmentation and glenohumeral joint clinical assessment in shoulder CT scans. *Artificial Intelligence in Medicine*. <https://www.sciencedirect.com/science/article/pii/S0933365725000661>
- Mishra, R., Gupta, A., & Verma, S. (2022). Attention-based CNN for diabetic foot ulcer detection. *Computers in Biology and Medicine*, 146, 105595. <https://doi.org/10.1016/j.combiomed.2022.105595>
- Oskolok, K. V., Monogarova, O. V., Garmay, A. V., & Milkina, V. S. (2025). One- and two-component digital image HDR-colorimetry: Technical

- challenges and analytical capabilities. *Talanta*.
<https://www.sciencedirect.com/science/article/abs/pii/S0039914025002267>
- Park, J., Kim, D., & Lee, H. (2022). RGB time-series for keloid monitoring: A computer-assisted approach. *Skin Research and Technology*, 28(5), 555–562. <https://doi.org/10.1111/srt.13150>
- Pezhhanfar, S., Farajzadeh, M. A., Ghaleh, M. K., & Hosseini-Yazdi, S. A. (2025). Unveiling a one-minute wastewater treatment using polyacrylonitrile and polyvinyl chloride followed by smartphone-based digital image colorimetry. *Journal of the Iranian Chemical Society*.
<https://link.springer.com/article/10.1007/s13738-025-03185-0>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234–241). Springer.
https://doi.org/10.1007/978-3-319-24574-4_28
- Ruccia, F., Zoccali, G., Cooper, L., Rosten, C., & Nduka, C. (2021). A three-dimensional scar assessment tool for keloid scars: Volume, erythema and melanin quantified. *Skin Research and Technology*.
<https://pubmed.ncbi.nlm.nih.gov/33974724/>
- Ruder, S. (2017). An overview of multi-task learning in deep neural networks. arXiv preprint arXiv:1706.05098. <https://arxiv.org/abs/1706.05098>
- Sharma, A., Agrawal, M., Dutta Roy, S., & Gupta, V. (2023). Better feature extraction using multi-encoder convolutional neural networks for optic cup segmentation from digital fundus images. *Research on Biomedical Engineering*. <https://link.springer.com/article/10.1007/s42600-022-00249-5>
- Talo, M., Aydin, A., & Kaya, S. (2023). Pre-processing for keloid image classification using CNNs. *Journal of Healthcare Engineering*, 2023, 1234567. <https://doi.org/10.1155/2023/1234567>
- Wang, J., Zhang, Y., Wang, Q., & Li, X. (2023). CNN–LSTM hybrid model for medical time-series image analysis. *Biomedical Signal Processing and Control*, 84, 104675. <https://doi.org/10.1016/j.bspc.2023.104675>

- Xu, M., Huang, K., & Qi, X. (2023). A Regional-Attentive Multi-Task Learning Framework for Breast Ultrasound Image Segmentation and Classification. IEEE Access. <https://ieeexplore.ieee.org/document/10016712>
- Xu, W., Yang, H., Shi, Y., Tan, T., Liu, W., Pan, X., Deng, Y., Gao, F., & Su, R. (2024). ERNet: Edge Regularization Network for Cerebral Vessel Segmentation in Digital Subtraction Angiography Images. IEEE Journal of Biomedical and Health Informatics. <https://ieeexplore.ieee.org/document/10356607>
- Xu, Z., Li, J., & Chen, Y. (2023). HSV color features for wound healing stage assessment. Journal of Biomedical Optics, 28(3), 035002. <https://doi.org/10.1117/1.JBO.28.3.035002>
- Yang, K., Dong, X., Tang, F., Ye, F., Chen, B., Liang, S., Zhang, Y., & Xu, Y. (2024). A transformer-based multi-task deep learning model for simultaneous T-stage identification and segmentation of nasopharyngeal carcinoma. Frontiers in Oncology. <https://pubmed.ncbi.nlm.nih.gov/38947898/>
- Zhang, Y., & Yang, Q. (2018). A survey on multi-task learning. IEEE Transactions on Knowledge and Data Engineering, 34(12), 5586–5609. <https://doi.org/10.1109/TKDE.2021.3070203>
- Zhang, Y., Li, H., Du, J., Qin, J., Wang, T., Chen, Y., Liu, B., Gao, W., Ma, G., & Lei, B. (2021). 3D Multi-Attention Guided Multi-Task Learning Network for Automatic Gastric Tumor Segmentation and Lymph Node Classification. IEEE Transactions on Medical Imaging. <https://pubmed.ncbi.nlm.nih.gov/33646948/>